

UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA



Profesor Guía:

**Ph.D Gabriel Saavedra
Mondaca.**

Informe de Tesis
para optar al Grado de
**Magíster en Ciencias de la
Ingeniería con Mención en
Ingeniería Eléctrica**

**Detección, clasificación y localización de
soft-failures en enlace óptico**

Concepción, 23 de marzo de 2026

Efraín Andrés San Martín Ayala

Universidad de Concepción
Facultad de Ingeniería
Departamento de Ingeniería Eléctrica

Profesor Patrocinante:
Ph.D Gabriel Saavedra Mondaca.

DETECCIÓN, CLASIFICACIÓN Y LOCALIZACIÓN DE SOFT-FAILURES EN ENLACE ÓPTICO

Efraín Andrés San Martín Ayala

Informe de Tesis
para optar al Grado de

Magíster en Ciencias de la Ingeniería con Mención en Ingeniería Eléctrica

23 de marzo de 2026

Resumen

La presente tesis aborda la detección, clasificación y localización de soft-failures en enlaces ópticos coherentes, con foco en un esquema de operación que permita pasar desde una alerta temprana a un diagnóstico accionable. Para ello, se desarrolla y valida experimentalmente un pipeline en cascada sobre un enlace de 200 km (dos spans de 100 km) con tres etapas de amplificación. En este contexto se consideran tres formatos de modulación (DP-QPSK, DP-8QAM y DP-16QAM) y un conjunto de datos balanceado por formato compuesto por 2000 ventanas, incluyendo operación normal y escenarios representativos de degradación: reducción de ganancia en amplificación, pérdidas adicionales por span e interferencia no lineal.

En la primera etapa, la detección se formula como un problema operacional de una clase, entrenando el modelo únicamente con datos de operación normal a partir de indicadores de QoT medidos en el receptor. Se comparan distintos enfoques de detección y se selecciona un Autoencoder por su desempeño superior. Con entrenamiento base en DP-QPSK, el detector alcanza una precisión del 100 % en el formato de referencia y mantiene resultados consistentes al transferir hacia DP-8QAM (99 %) y DP-16QAM (100 %), evidenciando robustez frente a cambios de formato de modulación bajo el criterio de recalibración por formato utilizado.

En la segunda etapa, activada una vez detectada la condición anómala, el diagnóstico se aborda como un problema supervisado de clasificación multiclase utilizando telemetría de potencia transversal al formato de modulación. Se construye un conjunto de características físicas basado en desviaciones respecto de una línea base normal: deltas de ganancias de amplificación y deltas de pérdidas por span, lo que permite asociar patrones anómalos a componentes o segmentos físicos del enlace. Con este diseño, la clasificación entrega directamente la localización mediante el mapeo clase-componente. En la evaluación de modelos, Random Forest logra desempeño perfecto en el conjunto de prueba (precisión del 100 %, recall y F1 equivalentes a 1.0), mostrando separación prácticamente perfecta entre los tipos de degradación evaluados.

En conjunto, la tesis entrega una metodología experimental reproducible y un pipeline en cascada alineado con requerimientos operacionales: detección robusta usando únicamente QoT disponibles en el receptor y diagnóstico mediante variables interpretables asociadas a la cadena de amplificación y spans, habilitando clasificación y localización para apoyar decisiones de operación y mantenimiento en redes ópticas.

Agradecimientos

En primer lugar, agradezco a Dios por permitirme llegar hasta donde he llegado, darme las fuerzas para continuar en cada desafío que aparece en mi vida y por mantenerme firme en mis propósitos.

Agradezco al proyecto Fondecyt 1231826 y a mi profesor guía, Gabriel Saavedra, por siempre apoyarme y darme las herramientas necesarias para poder desempeñarme en los múltiples proyectos que he tenido el agrado de participar. Gracias por sus consejos y su mentoría en cada una de mis travesías de experimentación en el laboratorio.

A los chicos del laboratorio, Cristóbal M., Leonardo, Francisca, Diego y Cristóbal V., por su compañía y apoyo al momento de experimentar o pasarlo bien en el laboratorio, comiendo pizzas, conversando o escuchando música en el televisor.

A mi familia, especialmente a mis padres, quienes han sido el apoyo incondicional más grande que he tenido en mi vida, estando ahí en todas las etapas, preocupándose siempre por mi bienestar.

A Oscar, por ser un gran amigo a lo largo de muchos años y ser parte de mi familia acá en Concepción, considerándolo como un hermano.

Y finalmente, a mi polola Denisse, por motivarme estos últimos meses a concluir este trabajo y ser una parte muy especial en mi vida. Tu compañía y amor han sido muy importantes en esta última etapa académica.

A todos ustedes, gracias

Índice general

Resumen	I
Agradecimientos	II
Índice de figuras	VI
Índice de tablas	IX
1. Introducción	1
2. Estado del arte	3
2.1. Discusión	9
2.2. Definición del problema	11
3. Hipótesis, objetivos y metodología	12
3.1. Hipótesis	12
3.2. Objetivos	12
3.2.1. Objetivo general	12
3.2.2. Objetivos específicos	12
3.3. Alcances y limitaciones	13
3.3.1. Alcances	13
3.3.2. Limitaciones	13
3.4. Metodología	14
3.4.1. Diseñar y configurar el enlace óptico para realizar las mediciones en dife- rentes condiciones de operación	15
3.4.2. Desarrollar un método automatizado para la extracción de datos del enlace óptico propuesto	15
3.4.3. Preprocesar los datos obtenidos, entrenar y validar algoritmos de apren- dizaje automático para la detección de soft-failures	16
3.4.4. Desarrollar y validar un sistema de clasificación y localización de soft- failures mediante la identificación de patrones anómalos asociados a dis- positivos o segmentos específicos a lo largo del enlace, evaluando el ren- dimiento de los modelos utilizados	18

4. Marco teórico	19
4.1. Introducción	19
4.2. Redes Ópticas y Desafíos de su Crecimiento	19
4.3. Parámetros QoT y Potencia Óptica	21
4.3.1. BER	21
4.3.2. OSNR	23
4.3.3. Potencia Óptica	25
4.3.3.1. Set-up experimental para potencia de entrada vs Pre-FEC BER	26
4.4. Componentes de un enlace óptico	27
4.4.1. Amplificadores de Fibra Dopados con Erblio (EDFA)	28
4.4.2. Wavelength Selective Switches (WSS)	29
4.4.3. Atenuadores Ópticos Variables (VOA)	30
4.4.4. Transceptor Coherente	30
4.4.5. Fibra Óptica Monomodo Estándar (SMF)	31
4.5. Detección y diagnóstico de anomalías	32
4.5.1. Algoritmos de Aprendizaje No Supervisado para Detección	32
4.5.1.1. Isolation Forest	32
4.5.1.2. DBSCAN	33
4.5.1.3. Autoencoder	34
4.5.2. Algoritmos de Aprendizaje Supervisado para Diagnóstico de Anomalías .	35
4.5.2.1. Random Forest	36
4.5.2.2. Support Vector Machine (SVM)	37
4.5.2.3. Multi-Layer Perceptron (MLP)	37
4.5.3. Preprocesamiento en Machine Learning	38
4.5.3.1. Ingeniería de Características	38
4.5.3.2. Normalización de Características	39
4.6. Métricas de evaluación	40
4.6.1. Métricas para detección (clasificación binaria)	40
4.6.2. Métricas para diagnóstico (clasificación multiclase)	40
5. Implementación experimental y resultados	42
5.1. Diseño e implementación del enlace óptico experimental para realizar las medi- ciones en diferentes condiciones de operación.	42
5.1.1. Equipamiento Experimental	44
5.1.2. Parámetros de Operación del Enlace	47
5.2. Método automatizado para la extracción de datos	48

5.3.	Preprocesamiento y aplicación de algoritmos de Machine Learning para la detección de soft-failures.	51
5.3.1.	Ventaneo temporal y construcción de muestras	51
5.3.2.	Tratamiento de lecturas anómalas dentro de la ventana	52
5.3.3.	Selección de características para detección	53
5.3.4.	Normalización por formato y clipping	54
5.3.5.	Selección del formato de referencia para entrenamiento (DP-QPSK) . . .	54
5.3.6.	Modelos evaluados para detección y criterio de selección	54
5.3.7.	Calibración operacional del umbral de decisión (autoencoder)	55
5.3.8.	Resultados de detección: evaluación in-format y transferencia por formato	55
5.3.9.	Evaluación reverse-transfer y discusión	56
5.4.	Clasificación y localización de soft-failures	58
5.4.1.	Ingeniería de características a partir de mediciones del enlace	58
5.4.2.	Criterio de rechazo ante activaciones espurias de la detección	59
5.4.3.	Análisis exploratorio y selección de variables	59
5.4.4.	Construcción del dataset y protocolo de entrenamiento	60
5.4.5.	Modelos evaluados para clasificación	61
5.4.6.	Resultados de clasificación	61
5.4.7.	Mapecto de localización	62
6.	Conclusiones y trabajo futuro	63
6.1.	Conclusiones	63
6.2.	Limitaciones	65
6.3.	Trabajo futuro	65
7.	ANEXOS	67
7.1.	ANEXO: Figuras Complementarias	67
7.2.	ANEXO: Código Utilizado	69
7.3.	ANEXO: Hojas de Datos y Documentación Técnica Relevante	73

Índice de figuras

2.1. Set-Ups experimentales propuestos en literatura. a) 1 señal, b) 2 señales.	5
2.2. Precisión obtenida en detección (a) e identificación (b) considerando diferentes características de ventana.	7
3.1. Esquema general de la metodología en cascada.	14
3.2. Esquema general de la etapa de detección propuesta.	17
4.1. SF reflejada en variaciones (en largo plazo) del BER.	20
4.2. Algunos tipos de SF: a) Filter Shift (FS), b) Filter Tightening (FT), c) IASEN (ruido ASE incrementado).	21
4.3. Principio de funcionamiento de la FEC.	22
4.4. Set-up para caracterización Pre-FEC BER vs OSNR mediante inyección de ASE.	24
4.5. Gráfica Pre-FEC BER vs OSNR para diferentes formatos de modulación.	25
4.6. Set-up experimental para potencia de entrada a fibra vs Pre-FEC BER.	26
4.7. Variaciones del Pre-FEC BER a diferentes potencias de entrada al sistema para diferentes formatos de modulación. Fuente: autoría propia.	27
4.8. WSS de Finisar.	30
4.9. Transceptores coherentes montados en módulo programable “Cassini”.	31
4.10. Ilustración del principio de Isolation Forest.	33
4.11. Proceso de DBSCAN.	34
4.12. Arquitectura de un Autoencoder.	35

4.13. Esquema conceptual de Random Forest.	36
4.14. Esquema conceptual de SVM.	37
4.15. Esquema conceptual de MLP.	38
5.1. Diagrama del enlace óptico experimental de 200 km implementado.	43
5.2. Vista general del <i>set-up</i> experimental montado en el Laboratorio de Optoelectrónica.	45
5.3. Ejemplo de inicio de sesión y configuración de potencia de salida del transceptor de manera manual mediante PuTTY. Fuente: Autoría propia.	48
5.4. Ejemplo de configuración manual de un EDFA PA. Fuente: Autoría propia.	49
5.5. Matriz de correlación de características candidatas para detección.	53
5.6. Matrices de confusión para detección con entrenamiento base DP-QPSK.	56
5.7. Resultados reverse-transfer para detección.	57
5.8. Histogramas condicionados por clase para ΔG_1 , ΔG_2 , ΔG_3 , ΔL_1 y ΔL_2 . Fuente: Autoría propia.	60
5.9. Matrices de confusión para clasificación multiclase en el subconjunto de prueba: (a) Random Forest, (b) SVM, (c) MLP. Fuente: Autoría propia.	61
7.1. Set-up utilizado en la investigación (16)	67
7.2. Set-up utilizado en la investigación (29).	67
7.3. Set-up utilizado en la investigación (15).	68
7.4. Set-up utilizado en la investigación (25).	68
7.5. Especificaciones del EDFA Thorlabs 100S. Fuente:[37]	73
7.6. Extracto del datasheet del trasceptor coherente Lumentum CFP2-DCO. Fuente:[38]	74

7.7. Atributos de la fibra óptica monomodo estándar G.652.D según la recomendación ITU-T.	74
7.8. Extracto del datasheet del Chasis M6200-CH2U. Fuente:[40]	75
7.9. Extracto del datasheet del EDFA Booster Amplifier. Fuente:[41]	75
7.10. Extracto del datasheet del EDFA Pre-Amplifier. Fuente:[42]	75

Índice de tablas

2.1. Resumen comparativo de las investigaciones previas.	8
3.1. Resumen de variables utilizadas por etapa en la metodología propuesta.	15
4.1. Especificaciones técnicas comparativas de los amplificadores EDFA BA y PA. . .	28
4.2. Características técnicas relevantes del WSS flexible de Finisar.	29
4.3. Parámetros típicos de una fibra óptica monomodo estándar según la norma ITU-T G.652.D.	31
5.1. Listado de instrumentos utilizados en el experimento	44
5.2. Detalles de implementación de los escenarios de falla	46
5.3. Parámetros de Operación del Enlace en Estado Normal	47
5.4. Extracto de muestras iniciales de estados normales (ID_Falla 0) para los formatos de modulación DP-QPSK y DP-16-QAM, relevantes para la detección de SF. . .	50
5.5. Ejemplo de estructura del dataset por ventana (60 s): características de QoT y telemetría de potencias.	51
5.6. Muestras representativas a nivel de ventana del conjunto de datos construido (DP-QPSK, DP-8QAM y DP-16QAM).	52
5.7. Comparación de modelos de detección en DP-QPSK (conjunto de evaluación). .	55
5.8. Desempeño del autoencoder en detección por formato (transferencia con recalibración por formato).	56
5.9. Comparación de desempeño de clasificadores (promedios ponderados, 80/20). . .	62
5.10. Regla de mapeo clase→ubicación en el enlace.	62

Siglas

BER Bit Error Rate

DP-QPSK Dual Polarization Quadrature Phase Shift Keying

EDFA Erbium Doped Fiber Amplifier

EON Elastic Optical Networks

FS Filter Shift

FT Filter Tightening

HF Hard-Failures

IoT Internet of Things

ML Machine Learning

NLI Nonlinear Interference

OSA Optical Spectrum Analyzer

OSC Canales de Supervisión Óptica

OSNR Optical Signal-to-Noise Ratio

QoS Quality of Service

QoT Quality of Transmission

SDON Software Defined Optical Networks

SF Soft-Failures

SMF Single Mode Fiber

SSH Secure Shell

SVM Support Vector Machines

VOA Variable Optical Attenuator

WDM Wavelength Division Multiplexing

WSS Wavelength Selective Switch

1. Introducción

En las últimas décadas, las redes de fibra óptica se han consolidado como un componente esencial de las telecomunicaciones modernas, al permitir la transmisión de grandes volúmenes de información con bajas pérdidas y latencias reducidas[1]. Este rol central se ha intensificado a medida que aumentan las demandas de conectividad y capacidad, lo que impone mayores exigencias a la operación y al mantenimiento de los enlaces de transmisión.

En este contexto, las fallas en redes ópticas suelen agruparse en dos categorías. Por una parte, las *hard-failures* (HF) producen interrupciones abruptas del servicio y, en general, son más fáciles de detectar. Por otra parte, las *soft-failures* (SF) se manifiestan como degradaciones graduales de la calidad de transmisión, sin interrumpir inmediatamente el servicio. Estas degradaciones suelen reflejarse en un incremento del *bit error rate* (BER) y en un deterioro del *optical signal-to-noise ratio* (OSNR).[2, 3]

Las SF pueden originarse en distintos mecanismos de la capa física. Entre ellos se incluyen el envejecimiento de componentes, la reducción de ganancia en etapas de amplificación, la aparición de atenuación adicional en tramos de fibra[4], la desconfiguración o degradación de filtros, y la presencia de interferencia no lineal (*nonlinear interference*, NLI)[5]. Debido a su naturaleza progresiva, estas fallas pueden pasar desapercibidas durante períodos prolongados y, si no se abordan oportunamente, conducir a degradaciones severas del servicio e incluso evolucionar hacia fallas abruptas[1, 4, 6].

A nivel operacional, la detección de SF representa un desafío relevante. En redes en operación, la supervisión del desempeño suele realizarse principalmente en los transceivers, donde se monitorea el BER como indicador de operación adecuada[7]. Sin embargo, cuando se observa un BER degradado, la identificación de la causa y su localización demanda pruebas adicionales en nodos intermedios y la intervención de personal especializado, lo que incrementa los costos operativos y prolonga los tiempos de diagnóstico.

La complejidad se agrava bajo condiciones realistas de operación, donde el tráfico, las configuraciones y los formatos de modulación pueden variar dinámicamente. En dichos escenarios, el uso de umbrales estáticos dificulta la detección temprana de degradaciones y hace que el ajuste fino de parámetros de monitoreo se vuelva un proceso costoso, poco escalable y propenso a retrasos

en el diagnóstico[8].

Motivado por estas limitaciones, se ha impulsado el uso de mecanismos automatizados e inteligentes para el monitoreo y la gestión de fallas. En particular, el aprendizaje automático (*machine learning*, ML) ha surgido como un habilitador para apoyar la automatización en redes ópticas, permitiendo analizar parámetros monitoreados y tomar decisiones basadas en patrones aprendidos desde datos[8, 9, 10].

No obstante, desde una perspectiva de operación, la detección por sí sola resulta insuficiente para una gestión eficiente de la red. Para habilitar acciones de mitigación oportunas y específicas, es necesario complementar la detección con la clasificación del tipo de falla y la localización de su origen, de modo de orientar el diagnóstico y la respuesta ante eventos anómalos[7, 11]. En consecuencia, marcos integrados que aborden detección, clasificación y localización, y que además puedan implementarse con parámetros de monitoreo disponibles en equipamiento comercial, constituyen una línea de investigación relevante.

Bajo este marco, la presente tesis aborda el problema mediante un enfoque en cascada orientado a operación: una primera etapa orientada a la detección de condiciones anómalas como señal de alerta y, una vez activada dicha alerta, una segunda etapa destinada al diagnóstico, mediante clasificación y localización de la falla.

2. Estado del arte

Dada la naturaleza gradual y sutil de los síntomas asociados a las SF, que suelen quedar enmascarados dentro de las fluctuaciones normales de los parámetros de operación de la red, su identificación y localización precisa representa un desafío importante. En este contexto, la capacidad de anticipar y ubicar estas fallas resulta especialmente relevante para los operadores, ya que permite implementar medidas preventivas como la reubicación del tráfico o ajustes en los nodos de amplificación, minimizando el riesgo de interrupciones y degradaciones severas del servicio [12].

Tradicionalmente, la detección de fallos en redes ópticas se ha llevado a cabo mediante el monitoreo en puntos estratégicos de la red, como los nodos de ingreso y salida, utilizando técnicas de supervisión *in-line* y el análisis de parámetros de calidad de transmisión (QoT), como el BER. Una técnica propuesta en la literatura [7, 13] (validada en un entorno simulado) es la inspección a través de canales de supervisión óptica (OSC), donde se inyecta una señal de prueba en el nodo de ingreso y se mide el BER en el nodo de salida. Esto permite evaluar la calidad del enlace antes de ponerlo en operación. Sin embargo, el método requiere intervención humana para la localización precisa de la causa del fallo, lo cual puede resultar ineficiente y costoso.

La creciente complejidad de las redes ópticas y la gran cantidad de datos que generan los sistemas de monitoreo han impulsado el uso de algoritmos de ML para automatizar la detección, identificación y/o localización de fallas. Estos algoritmos han demostrado [9, 10] ser útiles para la predicción de fallas, la optimización del control de tráfico y la adaptación dinámica de los recursos de red en función de la demanda. En este marco, enfoques supervisados y no supervisados, como redes neuronales y modelos de *clustering* [14], se utilizan para detectar patrones anómalos en grandes volúmenes de datos, facilitando la identificación temprana de fallos en enlaces ópticos. Estas tecnologías han reducido la necesidad de intervención humana, y además permiten una respuesta más rápida y precisa ante degradaciones del servicio asociadas a la QoT.

Por ejemplo, el uso de ML puede facilitar el análisis conjunto de parámetros como el BER, el Q-factor y el OSNR, generando modelos que no solo detecten fallos, sino que también predigan su evolución en el tiempo [4]. Aunque los primeros trabajos en esta área han mostrado resultados alentadores, aún existen preguntas abiertas sobre qué parámetros son más relevantes y qué algoritmos son los más adecuados para el análisis de redes ópticas en entornos experimentales.

En relación con el diagnóstico apoyado en información espectral, tecnologías como los analizadores de espectro óptico (OSA) son útiles para monitorear el espectro en los enlaces en tiempo real y abren la posibilidad de apoyar la identificación y localización de fallas en redes ópticas. Una aplicación de esto se presenta en [7], donde se utilizaron diferentes OSAs en cada nodo (inicial, intermedios y final) del enlace planteado (10 spans de 100 km, modulación DP-QPSK, filtros de 37.5 GHz y una tasa de 120 Gb/s) y, mediante algoritmos de ML, fue posible la identificación y localización de diferentes tipos de SF al suministrar los espectros obtenidos en cada nodo del enlace, observando características como la frecuencia central, el ancho de banda y la simetría del espectro.

Otra estrategia investigada consiste en analizar las fluctuaciones del BER a lo largo del tiempo mediante algoritmos de ML para identificar posibles anomalías de manera sencilla. Una vez detectada una anomalía en el BER, se propone el uso de OSAs para analizar el espectro de la señal con el objetivo de determinar si la anomalía detectada corresponde a un tipo específico de falla [15]. Esto se logra utilizando algoritmos de clasificación que comparan el espectro obtenido con espectros característicos de diferentes fallas, alcanzando así una alta precisión en la identificación, cercana al 100 %.

En otro estudio [16], se propone un esquema de detección y clasificación de SF basado en el uso del espectro residual digital, el cual se obtiene directamente desde un receptor coherente (transceptor con módulo de procesamiento digital de señales (DSP) integrado), sin necesidad de equipos adicionales de hardware. Se simularon experimentalmente tres tipos de fallas (Filter Shift, Filter Tightening y cambio en la frecuencia del láser transmisor) mediante el ajuste del ancho de banda y la frecuencia central del WSS, además de la modificación de la frecuencia del transmisor. Esta técnica hace uso de un autoencoder (AE) y un clasificador de máquinas de soporte vectorial (SVM), mostrando una alta precisión en la identificación de fallas y alcanzando una exactitud del 96.45 % en escenarios experimentales. Si bien los transceptores coherentes comerciales incorporan DSP interno, el acceso a variables internas y salidas intermedias (p. ej., muestras I/Q o métricas post-DSP detalladas) no siempre está disponible ni estandarizado, y suele depender del fabricante. Por ello, enfoques que se basan en información interna del DSP pueden ver limitada su transferibilidad a escenarios con equipamiento comercial y acceso restringido.

A pesar de estos avances, la mayoría de los estudios previos se han centrado en enfoques basados en simulaciones o *set-ups* experimentales limitados a fallas relacionadas al espectro y utilizando configuraciones estáticas, sin explorar la variabilidad conjunta de parámetros como el BER,

OSNR, potencias de entrada y salida de cada amplificador y la potencia de llegada al receptor, frente a diferentes cantidades de canales interferentes (adyacentes a la señal principal) y formatos de modulación. Estos estudios tienden a simplificar los escenarios reales y no exploran todas las posibles adversidades que pueden enfrentar los enlaces actuales, lo que limita su aplicabilidad, en la operación diaria, en redes complejas.

Sin embargo, una serie de estudios [17, 18, 19] proponen una metodología para la detección de SF con el objetivo de mantener la información confidencial frente a terceros. Dicha metodología se basa en la aplicación de algoritmos de ML no supervisados basados en *clustering* (K-means, DBSCAN, HDBSCAN, OPTICS, Affinity Propagation y Spectral Clustering), utilizando valores de BER, OSNR y potencias de entrada y salida de EDFAs. Dentro de las condiciones experimentales reportadas se destacan dos escenarios.




Fig. 2.1: Set-Ups experimentales propuestos en [17]. a) 1 señal, b) 2 señales. Fuente: [17]

El primer escenario consistió en una red simple comprendida por dos transceivers (TX y RX) y cuatro spans de fibra monomodo estándar (SMF) de 70 km cada uno. Para compensar las pérdidas de señal, se utilizaron EDFAs. En este enlace, se introdujo una SF mediante un atenuador óptico variable (VOA) que redujo la potencia en el primer span. La transmisión se realizó a través de un único canal con una frecuencia de 193.1 THz, utilizando modulación DP-QPSK. Se indujeron cinco fallas distintas, con una duración de cinco minutos cada una, intercaladas con periodos aleatorios de funcionamiento normal. El análisis de los datos permitió identificar dos *clusters*: uno correspondiente al estado normal de la red y otro correspondiente al estado de falla.

El segundo escenario, una red más compleja, incluyó dos transceivers TX y dos RX operando en diferentes longitudes de onda (193.1 THz y 193.2 THz) sobre los mismos cuatro spans de fibra. Se emplearon *failure actuators* (FA) con WSSs para inducir tres posibles tipos de SF en cada span: una degradación de hasta 10 dB solo en el canal 1, solo en el canal 2, o en ambos.

Este escenario generó 12 estados de falla y uno normal, lo que permitió identificar 13 *clusters* mediante algoritmos de *clustering* para su análisis.

En ambos escenarios, la aplicación del algoritmo DBSCAN para la detección de estados normales y de falla arrojó resultados consistentemente altos en términos de las métricas de evaluación, las cuales fueron promediadas para facilitar la comparación. Específicamente, en el escenario de red simple, el promedio de las métricas para DBSCAN alcanzó un valor de 0.874. De manera similar, en el escenario de red compleja, el promedio de las métricas se situó en 0.865. Estos valores, que consideran métricas como Homogeneidad, Completitud y el Índice Rand Ajustado, demuestran la eficacia de DBSCAN para la detección de SF.

El uso de DBSCAN para la detección de anomalías también fue aplicado por [20], donde el enfoque para la detección de SF se basó en un aprendizaje híbrido auto-supervisado. Inicialmente, se empleó DBSCAN para extraer patrones normales y anómalos de datos obtenidos en un ambiente de simulación, considerando la potencia óptica medida en cada nodo y el BER en el receptor. Estos patrones identificados por DBSCAN se utilizaron para etiquetar los datos y posteriormente entrenar un clasificador supervisado basado en una red neuronal. Para mejorar la precisión de la detección, especialmente en ausencia de suficientes datos de fallas, se incorporó la estimación de la incertidumbre del modelo mediante *MC dropout* en la red neuronal. Este enfoque alcanzó una tasa de detección de SF de hasta el 94 % en las evaluaciones. En esta investigación se emuló el mal funcionamiento de EDFAs, desplazamiento de la frecuencia del láser y FT.

En el marco de la utilización de parámetros como el BER, el OSNR y la potencia, es importante mencionar la investigación [21], donde, a través de simulaciones, se desarrolló un modelo basado en redes definidas por software (SDON) para la detección e identificación de SF. Este modelo emplea un autoencoder basado en LSTM (LSTM-AE) como clasificador binario para identificar secuencias anómalas en series de tiempo, seguido de un clasificador LSTM multicategoría para determinar el tipo específico de falla. Los parámetros QoT monitoreados incluyen potencia óptica recibida, corriente del láser transmisor, OSNR y BER, los cuales fueron registrados a intervalos regulares.

El enfoque adoptado es destacable por su capacidad para procesar correlaciones temporales en los datos, maximizando así la eficacia en la identificación de comportamientos anómalos. Esto resulta especialmente útil en el análisis de redes ópticas en el largo plazo, ya que las ventanas de tiempo utilizadas consideraban semanas completas para cada muestra. En las simulaciones realizadas, que contemplaron fallas asociadas al láser del transmisor, EDFAs y NLI, el modelo

alcanzó una precisión promedio del 99.7 %.

Si bien estos resultados subrayan el potencial de aplicar modelos para analizar series de tiempo y detectar SF de manera eficiente, incluso en escenarios complejos, también evidencian una limitación: el tiempo de muestreo requerido es considerablemente extenso. En un contexto experimental, donde se buscan respuestas en plazos más cortos, depender de muestras de semanas completas puede dificultar la implementación práctica. Esto plantea la necesidad de explorar enfoques complementarios que permitan detección temprana a corto plazo, sin comprometer la precisión del análisis.

En contraste, se ha evidenciado [4] la detección e identificación de SF analizando ventanas de tiempo con menor duración, utilizando solo el BER, por ser una métrica directa del estado de la señal, altamente sensible a cambios asociados a fallas, y capaz de reflejar patrones característicos.

Para una obtención de resultados significativos, se muestra que es esencial ajustar de manera adecuada el tiempo de muestreo y el tamaño de la ventana. Se utilizaron varias configuraciones diferentes, siendo un tiempo de muestreo de 22 s y un tamaño de ventana de 18 min los mínimos necesarios para alcanzar los mejores rendimientos para la detección (superior al 99 %). Para la identificación solo fue necesario un tiempo de muestreo de 3 s y ventanas de 5 min (alcanzando un 100 % de precisión).




Fig. 2.2: Precisión obtenida en detección (a) e identificación (b) considerando diferentes características de ventana. Fuente: [4]

Para la detección, se utilizaron diferentes modelos: Random Forest, SVM Binario y una red neuronal, siendo el SVM Binario el que obtuvo el mejor rendimiento. Para la identificación solo

se utilizó una red neuronal con dos capas ocultas.

A continuación, en la Tabla 2.1, se ofrece un resumen comparativo de las principales investigaciones en el campo de la detección, clasificación y localización de SF en redes ópticas, detallando si el estudio se llevó a cabo de manera simulada o experimental, los objetivos de cada uno, las fallas abordadas, los parámetros del enlace utilizados y los algoritmos de ML aplicados.

Año	Tipo	Objetivo	Fallas	Parámetros	Modelos
2018[7]	Simulación	Clasificación, Localización	FT, FS, Laser Drift (LD)	BER, Espectro	Árboles de decisión, SVM
2018[4]	Experimental	Detección, Clasificación	FS, Ganancia reducida EDFA	BER, Espectro	Random Forest, SVM y NN
2020[22]	Simulación	Clasificación	FS, FT, Ruido ASE y NLI	Densidad Espectral	CNN
2022[20]	Simulación	Detección, Localización	FT, EDFA, LD y NLI	Potencia de la señal, BER	DBSCAN, NN y BNN
2023[16]	Simulación y Experimental	Detección, Clasificación	FT, FS y LD	Espectro digital, BER	Auto-Encoder (AE) y SVM
2023[23]	Simulación y Experimental	Detección, Clasificación	FT y FS	PSD	CNN, ANN y GPC
2024[15]	Experimental	Detección, Clasificación	FS e ISASEN	BER, Espectro	AE, CNN, KNN y SVM
2024[17]	Experimental	Detección	Atenuación en el enlace	BER, OSNR, EDFA P_{in} y P_{out}	K-means, DBSCAN, HDBSCAN, OPTICS
2024[14]	Experimental	Detección	Atenuación en el enlace	OSNR, P_{in} en EDFAs	Fuzzy C-means
2024[24]	Experimental	Clasificación	FS, FT y Atenuación	BER, OSNR	Red Neuronal
2025[21]	Simulación	Detección, Clasificación	NLI, Problema láser y EDFA	BER, OSNR, Potencia recibida y Corriente láser	LSTM-AE, LSTM, GRU, RF y SVM

Tabla 2.1: Resumen comparativo de las investigaciones previas.

La tabla muestra la diversidad de algoritmos de ML que se han explorado activamente para abordar las SF, incluyendo desde árboles de decisión y SVM hasta redes neuronales y métodos de *clustering*. A pesar de esta amplia gama de técnicas aplicadas, una limitación común en muchos de los estudios resumidos es la falta de una consideración explícita de la variabilidad de formatos de modulación. Si bien las investigaciones [22, 24] abordan el uso de diferentes

formatos de modulación para comparar el rendimiento de modelos, estos trabajos están basados en simulaciones. Esta prevalencia de simulaciones subraya la importancia de la validación experimental para asegurar la aplicabilidad y robustez en modelos para la detección, clasificación y/o localización de SF en escenarios más cercanos a las condiciones reales de operación.

2.1. Discusión

A pesar de que la investigación [19] introduce escenarios distintos, aún existen condiciones relevantes que podrían ser abordadas de manera más sistemática. En particular, un mismo enlace puede operar bajo diferentes formatos de modulación y con una cantidad variable de canales interferentes o adyacentes a la señal principal, considerando que en redes ópticas es habitual multiplexar una gran cantidad de canales mediante WDM. Esta variabilidad operacional modifica el comportamiento observado en los parámetros monitoreados y, por tanto, tensiona la capacidad de generalización de metodologías entrenadas en escenarios acotados o estáticos.

Un aspecto fundamental que se desprende de estas investigaciones es la selección de los datos de entrada utilizados por los algoritmos de *clustering* para realizar detección de fallas. A partir de ello, resulta natural incorporar descriptores más representativos del comportamiento temporal de las variables, tal como se plantea en [4]. Un ejemplo consiste en utilizar el valor promedio y/o la desviación estándar de parámetros ampliamente utilizados en la literatura (ver Tabla 2.1), tales como el BER, el OSNR y la potencia óptica a la entrada del receptor. Este tipo de caracterización permite capturar no solo niveles nominales, sino también la variabilidad asociada a degradaciones graduales, facilitando la diferenciación entre estados normales y condiciones anómalas.

Adicionalmente, no se observa en la literatura un modelo que haya sido entrenado bajo un formato de modulación y evaluado con muestras correspondientes a una modulación diferente, considerando además una cantidad variable de canales adyacentes a la señal principal. Esto deja un vacío en el desarrollo de modelos robustos que puedan aplicarse en múltiples escenarios operacionales, donde la configuración del enlace no es fija. En la práctica, los transceptores coherentes modernos son programables y permiten ajustar tanto la longitud de onda de operación como el formato de modulación en función de requerimientos de capacidad, margen de QoT o reconfiguraciones de red. En consecuencia, el “comportamiento normal” del enlace puede cambiar en el tiempo, y las estrategias de monitoreo se benefician de enfoques capaces de mantenerse estables frente a cambios de configuración y condiciones de carga.

En este contexto, resulta pertinente avanzar hacia metodologías experimentales orientadas a operación que, por un lado, sean robustas ante cambios de formato de modulación y escenarios de carga dinámica y, por otro, permitan activar mecanismos de diagnóstico cuando corresponda, entregando información accionable para apoyar la gestión de fallas y reducir tiempos de respuesta en condiciones más cercanas a la operación real.

2.2. Definición del problema

Como se ha evidenciado en la discusión previa, existe una clara necesidad de superar las limitaciones en la gestión de SF en redes ópticas. Las soluciones actuales, predominantemente basadas en simulaciones o en configuraciones experimentales estáticas, carecen de la robustez necesaria para operar eficazmente en entornos dinámicos, caracterizados por variabilidad en los formatos de modulación y por la presencia de múltiples canales adyacentes. Este vacío en la literatura y en las metodologías existentes dificulta el desarrollo de sistemas de monitoreo y gestión de fallas que sean verdaderamente autónomos y fiables en condiciones cercanas a la operación real.

En respuesta a esta problemática, el presente trabajo aborda el desafío de desarrollar un sistema orientado a operación que permita, en primer lugar, detectar SF de manera precisa y robusta frente a cambios en el formato de modulación y en la cantidad de canales adyacentes. Adicionalmente, con el fin de apoyar el diagnóstico y reducir los tiempos de respuesta ante eventos anómalos, el sistema busca complementar la detección con mecanismos de clasificación y localización, de modo de asociar la degradación observada a un tipo de falla y a su origen dentro del enlace. En conjunto, se propone una metodología experimental y se valida la capacidad de algoritmos de ML para abordar estas tareas integrando parámetros descriptivos del enlace, buscando aproximar el análisis a condiciones representativas de operación.

3. Hipótesis, objetivos y metodología

3.1. Hipótesis

La hipótesis a validar en este trabajo es la siguiente:

El desarrollo de un modelo en cascada de aprendizaje automático que incorpore características descriptivas de las variables de enlaces ópticos (como promedio y la desviación estándar del BER, el OSNR, potencias de entrada y salida de cada EDFA y la potencia óptica al receptor), permitirá una detección, clasificación y localización de soft-failures en sistemas de transmisión óptica con una precisión general superior al 90 %, independientemente del formato de modulación utilizado y la cantidad de canales adyacentes a la señal principal.

3.2. Objetivos

3.2.1. Objetivo general

El objetivo general del presente trabajo es:

Desarrollar y validar un sistema para la detección, clasificación y localización de soft-failures en redes ópticas, basado en el análisis de parámetros de calidad de transmisión y telemetría del enlace, comprobando su aplicabilidad bajo diferentes formatos de modulación y frente a una cantidad variable de canales interferentes o adyacentes.

3.2.2. Objetivos específicos

Alcanzar el objetivo general conllevará la realización de los siguientes objetivos específicos:

1. Diseñar e implementar el enlace óptico experimental para realizar mediciones en diferentes condiciones de operación.
2. Desarrollar un método automatizado para la extracción de parámetros del enlace óptico propuesto, garantizando una toma de muestras automatizada, trazable y ordenada.

3. Preprocesar los datos obtenidos, entrenar y validar algoritmos de aprendizaje automático para la detección de soft-failures, evaluando su robustez mediante conjuntos de datos obtenidos con diferentes formatos de modulación y bajo una cantidad variable de canales adyacentes o interferentes.
4. Desarrollar y validar un sistema de clasificación y localización de soft-failures mediante la identificación de patrones anómalos asociados a dispositivos o segmentos específicos a lo largo del enlace, evaluando el rendimiento de los modelos utilizados.

3.3. Alcances y limitaciones

3.3.1. Alcances

El presente trabajo aborda la detección y el diagnóstico de SF en un enlace óptico experimental, donde el diagnóstico comprende la clasificación del tipo de falla y la localización de su origen dentro del enlace. Para ello, se consideran SF inducidas en distintos elementos del sistema, con el fin de evaluar el desempeño de la metodología propuesta bajo condiciones controladas.

En particular, las SF abordadas en este trabajo corresponden a los siguientes tipos generales:

- **Ganancia reducida en EDFA:** simulada mediante variaciones en la ganancia de los amplificadores utilizados.
- **Interferencia no lineal (NLI):** asociada a condiciones de operación que inducen efectos no lineales en el enlace.
- **Atenuación en el enlace:** incorporada mediante atenuadores variables para emular, por ejemplo, un aumento del nivel de atenuación de la fibra o la adición de dispositivos pasivos en un *span* (tramo entre dos amplificadores).

3.3.2. Limitaciones

A pesar de los alcances planteados, el presente trabajo estuvo sujeto a ciertas limitaciones, principalmente derivadas del equipamiento disponible en el Laboratorio de Optoelectrónica y del escenario experimental considerado:

- El estudio se restringe a un conjunto de formatos de modulación: DP-QPSK, DP-8QAM y DP-16QAM.

- Debido a limitaciones de *hardware*, solo fue posible utilizar un único canal modulado. La interferencia asociada a canales adyacentes y la condición de carga dinámica se emulan mediante ruido ASE [25], lo cual permite representar escenarios con presencia variable de canales interferentes sin disponer físicamente de múltiples canales WDM modulados.
- El conjunto de SF analizadas se restringe a los tipos descritos en la subsección de alcances, lo que delimita el diagnóstico a los escenarios inducidos y medidos bajo las condiciones experimentales del enlace.

3.4. Metodología

A continuación, se describe la metodología propuesta para el desarrollo de cada objetivo específico previamente planteado. El presente trabajo se estructura como un esquema en cascada basado en aprendizaje automático: una primera etapa orientada a la detección de SF como señal de alerta y, una vez activada dicha alerta, una segunda etapa destinada al diagnóstico, mediante clasificación y localización de la falla. Esta lógica general se resume en el diagrama de bloques de la Fig. 3.1. El trabajo se llevó a cabo utilizando los instrumentos y dispositivos disponibles en el Laboratorio de Optoelectrónica de la Universidad de Concepción.




Fig. 3.1: Esquema general de la metodología en cascada: etapa de detección y etapa de clasificación/localización.

En la figura, la salida de la etapa de detección actúa como un gatillo operacional: ante una condición normal no se ejecuta diagnóstico adicional, mientras que ante una condición anómala se activa la segunda etapa, encargada de entregar un diagnóstico accionable (tipo de SF y su localización más probable dentro del enlace). Con esta estructura, la metodología separa explícitamente (i) la detección robusta a condiciones de operación, y (ii) el diagnóstico basado en telemetría asociada a componentes del enlace.

3.4.1. Diseñar y configurar el enlace óptico para realizar las mediciones en diferentes condiciones de operación

Para el desarrollo de este objetivo, es necesario poder diseñar y configurar un *set-up* experimental que permita realizar mediciones de parámetros relevantes del enlace bajo diferentes condiciones de operación, tanto en estados normales como en estados de fallas controladas. El *set-up* a implementar debe incluir componentes típicos de un enlace óptico, tales como transmisor, multiplexación/demultiplexación, etapas de amplificación, fibra óptica y receptor.

En coherencia con el pipeline de la Fig. 3.1, el diseño experimental contempla la adquisición de variables asociadas a cada etapa. En particular, para la etapa de detección se emplean variables de QoT medidas en el receptor (Pre-FEC BER y OSNR). Para la etapa de clasificación y localización, se emplea telemetría de potencias de entrada y salida de los EDFAs a utilizar en el enlace, a partir de las cuales se derivan características adicionales utilizadas para el diagnóstico. Este conjunto de variables se resume en la Tabla 3.1.

Etapa	Variables de entrada
Detección	Pre-FEC BER y OSNR
Clasificación/Localización	P_{in} y P_{out} de cada EDFA

Tabla 3.1: Resumen de variables utilizadas por etapa en la metodología propuesta.

El diseño del enlace debe permitir evaluar escenarios de referencia (condición normal) y escenarios con SF consistentes con los alcances del presente trabajo: (i) ganancia reducida en etapas de amplificación, (ii) atenuación adicional en *spans* (tramos) del enlace, y (iii) escenarios asociados a NLI bajo condiciones de carga dinámica, considerando variación de canales adyacentes a la señal principal emulada mediante ASE [25].

3.4.2. Desarrollar un método automatizado para la extracción de datos del enlace óptico propuesto

Los datos del enlace se obtendrán mediante un esquema automatizado de adquisición, con el fin de reemplazar la extracción manual actual y asegurar consistencia, rapidez y trazabilidad en las mediciones. En particular, se implementará un procedimiento que permita:

- Obtener desde el receptor los parámetros de QoT necesarios para la etapa de detección (Pre-FEC BER y OSNR).

- Obtener desde los dispositivos de amplificación la telemetría requerida para la etapa de clasificación y localización (potencias de entrada y salida por EDFA).
- Registrar y almacenar las mediciones con una tasa de muestreo de 1 segundo, de manera que sea posible construir series de tiempo homogéneas por escenario y por formato de modulación.
- Organizar los registros de manera ordenada por condición de operación (normal/falla), escenario y formato de modulación, permitiendo posteriormente segmentar los datos en ventanas temporales de 60s (60 muestras por ventana) y construir los conjuntos de datos utilizados para entrenamiento y evaluación posterior.

La automatización se implementará mediante *scripts* en Python, aprovechando los métodos de comunicación disponibles (por ejemplo, acceso remoto al receptor y control/consulta de parámetros en los dispositivos del enlace), permitiendo una toma de datos periódica, ordenada y trazable.

3.4.3. Preprocesar los datos obtenidos, entrenar y validar algoritmos de aprendizaje automático para la detección de soft-failures

En esta etapa se debe realizar el preprocesamiento necesario para garantizar la calidad de los datos y facilitar el entrenamiento y la validación de modelos. En particular, se aplicarán rutinas para filtrar valores inconsistentes y manejar mediciones fuera de rango cuando corresponda. Posteriormente, a partir de los registros ya organizados por escenario y por formato de modulación, se segmentarán todas las variables extraídas mediante ventaneo temporal, utilizando ventanas de 60 s muestreadas a 1 Hz. Para cada ventana (y variable extraída) se calcularán características descriptivas (promedio y desviación estándar) con el fin de representar el comportamiento de cada segmento temporal y facilitar la detección de patrones anómalos.

La detección se formulará como un problema operacional de una clase, entrenando los modelos únicamente con muestras correspondientes a operación normal. Con el fin de establecer el enfoque final de detección, se evaluarán y compararán distintos modelos no supervisados utilizados para detección de anomalías, incluyendo Isolation Forest, DBSCAN y un autoencoder. La comparación permitirá seleccionar el modelo de mejor desempeño para la detección de estados anómalos, en función de métricas de *precisión*, *recall* y *F1-score*, además de sus matrices de confusión.

Una vez seleccionado el modelo final de detección, se definirá un procedimiento de entrenamiento y calibración orientado a operación. En particular, el modelo se entrenará únicamente con datos normales de un formato de modulación específico (inicialmente DP-QPSK), aplicando normalización por formato, y se establecerá un umbral de decisión a partir del comportamiento del modelo bajo condición normal (sin utilizar muestras de falla para ajustar dicho umbral). Con esta configuración, se buscará obtener el mejor desempeño posible en detección (con métricas generales superiores al 90 %) bajo el formato de entrenamiento, de manera de fijar un modelo base para evaluación cruzada.

A continuación, el modelo entrenado se evaluará utilizando muestras obtenidas bajo formatos de modulación diferentes a los vistos durante el entrenamiento (DP-8QAM y DP-16QAM), con el objetivo de cuantificar su capacidad de generalización y su comportamiento frente a escenarios no vistos, incluyendo condiciones asociadas a carga dinámica. Para analizar la robustez de este criterio y estudiar si el formato de modulación utilizado en el entrenamiento influye en la capacidad de generalización, se repetirá el mismo procedimiento entrenando el modelo con datos normales de DP-8QAM y evaluándolo con los otros dos formatos, y luego entrenando con DP-16QAM y evaluándolo con los otros dos formatos. Este esquema permitirá verificar si el enfoque puede considerarse efectivamente agnóstico al formato de modulación, o si existen diferencias sistemáticas que afecten el rendimiento al transferir el modelo entre formatos.

La metodología de la etapa de detección, se muestra resumida en la siguiente figura:




Fig. 3.2: Esquema general de la etapa de detección propuesta.

3.4.4. Desarrollar y validar un sistema de clasificación y localización de soft-failures mediante la identificación de patrones anómalos asociados a dispositivos o segmentos específicos a lo largo del enlace, evaluando el rendimiento de los modelos utilizados

En este objetivo se desarrolla la etapa de diagnóstico del pipeline de la Fig. 3.1, compuesta por clasificación y localización de SF. En coherencia con el enfoque en cascada, esta etapa se activa únicamente cuando la etapa de detección indica una condición anómala, de modo que el sistema entregue un diagnóstico accionable (tipo de falla y su origen dentro del enlace).

Para esta etapa es necesario utilizar los valores extraídos asociados a los EDFAs del enlace, en particular las potencias de entrada y salida por dispositivo, procesadas en las mismas ventanas temporales utilizadas para construir los conjuntos de datos. A partir de estas variables se construyen características adicionales que describen el estado del enlace, incluyendo variables derivadas asociadas a ganancias/pérdidas y, especialmente, diferencias respecto a un comportamiento de referencia obtenido a partir de operación normal. En esta etapa, la condición normal no se utiliza como clase objetivo del clasificador; sin embargo, se emplea para calcular los valores de referencia necesarios para las características tipo “delta”.

Para la clasificación se evaluarán tres distintos modelos supervisados (Random Forest, SVM y MLP), comparando su desempeño para discriminar entre los tipos de SF considerados. La localización se obtiene a partir del mapeo entre la clase estimada y el componente o segmento físico asociado dentro del enlace, permitiendo identificar el origen más probable de la degradación. Finalmente, el desempeño de esta etapa se reportará mediante métricas estándar de clasificación y matrices de confusión, analizando el rendimiento por clase y su impacto en el diagnóstico operacional.

4. Marco teórico

4.1. Introducción

El presente capítulo establece el marco conceptual y técnico sobre el cual se sustenta la investigación en torno a la detección de SF en enlaces ópticos mediante el uso de ML, y su diagnóstico posterior mediante clasificación y localización. El propósito de esta sección es proporcionar al lector los fundamentos necesarios para comprender los fenómenos físicos que rigen la transmisión en redes ópticas, las métricas de calidad de transmisión (QoT) utilizadas para caracterizar el estado del enlace, la naturaleza de las fallas que pueden ocurrir en estos sistemas, y los principios generales de los algoritmos de ML aplicados en este contexto.

4.2. Redes Ópticas y Desafíos de su Crecimiento

En los últimos años, la demanda por servicios de telecomunicaciones ha crecido de manera exponencial debido a la adopción de tecnologías emergentes como las redes de quinta generación (5G) [26], la proliferación de servicios en la nube y la transmisión de video en alta definición. Estas aplicaciones requieren de redes capaces de manejar grandes volúmenes de tráfico con una latencia mínima y una alta confiabilidad, lo que ha impulsado el desarrollo de infraestructuras ópticas más eficientes y flexibles [3]. Dentro de estas tecnologías, las redes ópticas elásticas (EONs) se destacan por su capacidad para maximizar el uso del espectro y adaptarse a las demandas variables del tráfico [27]. A diferencia de las redes WDM tradicionales de grilla fija (usualmente de 50 o 100 GHz), las Redes Ópticas Elásticas (EONs) operan sobre una grilla flexible (flexible-grid). Esto permite asignar recursos espectrales de forma dinámica y granular, adaptando el ancho de banda del canal óptico y el formato de modulación a los requerimientos específicos del tráfico. Esta flexibilidad, si bien maximiza la eficiencia espectral, también introduce mayor complejidad en la gestión y monitoreo de la red, particularmente en términos de gestión de fallos y mantenimiento de la calidad de transmisión (QoT).

El correcto funcionamiento de una red óptica depende de su capacidad para mantener la calidad de servicio (QoS) dentro de los parámetros aceptables, incluso en presencia de fallas. Estas fallas pueden clasificarse en dos categorías: *hard-failures* y *soft-failures*. Las HF se caracterizan por

la interrupción completa de la señal, generalmente causada por eventos como cortes de fibra o fallas severas en los equipos de red. Estos requieren una restauración inmediata del tráfico mediante la utilización de recursos alternativos, ya que pueden generar una pérdida significativa de datos en muy poco tiempo [7]. En cambio, las SF representan degradaciones más sutiles en la QoT, que aunque no interrumpen completamente el servicio, pueden afectar progresivamente la calidad de la señal, aumentando el BER y, en consecuencia, disminuyendo el OSNR [4]. A medida que las SF evolucionan sin ser corregidas, pueden eventualmente transformarse en HF, comprometiendo gravemente la integridad de la red y la experiencia del usuario.




Fig. 4.1: SF reflejada en variaciones (en largo plazo) del BER. Fuente: [15]

Las SF no interrumpen inmediatamente el servicio, pero su calidad se ve comprometida. Estas fallas pueden ser causadas por diversos factores dentro de las redes ópticas, entre los que destacan:

- **Envejecimiento y degradación de componentes:** Los componentes ópticos, como los amplificadores de fibra dopada con erbio (EDFA), los conmutadores selectores de longitud de onda (WSS), los transceptores y la fibra óptica, se degradan con el tiempo. Por ejemplo, el envejecimiento de los EDFAs puede provocar un aumento en el ruido de emisión espontánea amplificada (ASE) y/o una disminución en la corriente del láser de bombeo [12], lo que afecta la calidad de la señal e incrementa el BER, especialmente en enlaces largos con múltiples amplificadores.




Fig. 4.2: Algunos tipos de SF: a) Filter Shift (FS), b) Filter Tightening (FT), c) IASEN (ruido ASE incrementado). Fuente: [22]

- **Desalineación espectral y fallos de filtro:** Utilizar WSSs en cascada, esenciales para el ruteo y la conmutación, así como para el filtrado de señales, puede provocar desalineaciones en el espectro de los canales [11], por envejecimiento o variaciones en temperatura. Esto puede generar interferencias cruzadas entre canales (XCI), asimetrías (FS) o estrechamientos en el espectro (FT), lo que a su vez puede afectar al OSNR y aumentar el BER.
- **Fallas por interferencia no lineal (NLI):** La NLI representa también una fuente de degradación, especialmente a medida que se incrementa la potencia de la señal transmitida[22]. Este fenómeno ocurre debido a la interacción de la luz con el medio de la fibra, generando efectos como la auto-modulación de fase y la modulación cruzada de fase, los cuales introducen componentes espectrales no deseadas que pueden interferir con la señal útil, manifestándose como un aumento progresivo del BER.

4.3. Parámetros QoT y Potencia Óptica

La QoT de un enlace óptico se evalúa mediante diversas métricas que reflejan la integridad y fiabilidad de la señal. Entre las más relevantes para caracterizar el estado del enlace se encuentran el BER, el OSNR y la potencia óptica.

4.3.1. BER

El BER es una métrica fundamental que cuantifica el número de errores de bit en relación con el total de bits transmitidos en un período de tiempo determinado. Se define como:

$$\text{BER} = \frac{\text{Número de bits erróneos}}{\text{Número total de bits transmitidos}} \quad (4.1)$$

En los sistemas de transmisión óptica modernos, no todos los bits erróneos iniciales impactan

al usuario final. Esto se debe a la implementación de técnicas de Corrección de Errores Hacia Adelante (FEC), un proceso digital que añade bits de redundancia (paridad) a los datos en el transmisor. En el receptor, un decodificador utiliza estos bits de paridad para detectar y corregir una cantidad limitada de errores ocurridos durante la transmisión, como se ilustra en la Figura 4.3.




Fig. 4.3: Principio de funcionamiento de la FEC. El codificador añade bits de paridad en el transmisor, y el decodificador los utiliza para corregir errores en el receptor. Fuente: [28]

Debido a este proceso, se distinguen dos tipos de BER. En este trabajo, la métrica utilizada es el Pre-FEC BER, ya que representa un indicador más sensible del estado físico del enlace: aunque el tráfico pueda mantenerse con BER post-FEC cercano a cero, un aumento en Pre-FEC BER suele ser una señal temprana de degradación.

En el enlace experimental, el Pre-FEC BER se obtiene directamente desde el receptor coherente integrado en el módulo CFP2-DCO utilizado. Es importante notar que, cuando no se habilita una secuencia de prueba PRBS, el BER no se mide por comparación directa contra un patrón conocido, sino que se estima internamente a partir de métricas del procesamiento digital del receptor y del bloque FEC. Operacionalmente, esto implica que el transceptor reporta un estimador continuo del Pre-FEC BER actualizado de forma periódica (según el período de reporte configurado en el módulo).

Adicionalmente, el módulo permite configurar el modo de FEC mediante perfiles compatibles, particularmente “15percent Denali” (con un 15 % overhead de redundancia asociado al esquema FEC). Esto incrementa la tolerancia del enlace a degradaciones del canal a costa de redundancia adicional. Bajo este contexto, el Pre-FEC BER actúa como un sensor directo de degradación: un aumento sostenido en este valor indica un deterioro en la calidad de la señal recibida, lo cual es coherente con la presencia de SF, incluso si la corrección FEC todavía puede mantener el servicio operativo.

4.3.2. OSNR

El OSNR es una métrica que cuantifica la relación entre la potencia de la señal óptica y la potencia del ruido óptico dentro de un ancho de banda de referencia. Comúnmente se expresa en decibeles (dB) y se define como:

$$\text{OSNR}_{\text{dB}} = 10 \log_{10} \left(\frac{P_{\text{señal}}}{P_{\text{ruido}}} \right). \quad (4.2)$$

En enlaces amplificados, el OSNR se degrada principalmente por la acumulación de ruido ASE introducido por los EDFAs y por pérdidas distribuidas a lo largo del enlace. En términos operacionales, una disminución del OSNR suele correlacionarse con un aumento del BER y con una reducción del margen de desempeño del enlace. Por este motivo, el OSNR es ampliamente usado como un indicador de QoT para monitoreo y detección temprana de degradaciones.

En este trabajo se distinguen dos formas de OSNR relevantes. Por un lado, para la caracterización experimental de la relación Pre-FEC BER vs OSNR (Fig. 4.5), el OSNR se midió con un analizador de espectro óptico (OSA), de manera de disponer de un valor trazable asociado al espectro óptico. Por otro lado, en la adquisición de datos para los modelos de detección, se emplea la métrica disponible en el propio transceptor coherente (reportada por el receptor como “OSNR Estimate”), la cual corresponde a una estimación interna calculada por el DSP del módulo.

La Fig. 4.4 muestra el set-up utilizado para barrer el OSNR de forma controlada en el experimento de BER vs OSNR. La señal óptica del transmisor se combinó con ruido ASE mediante un splitter 50:50. El ASE se generó utilizando una cadena de amplificación dedicada y su nivel se controló mediante VOAs en la rama de ruido, permitiendo modificar la potencia de ASE inyectada y, por tanto, el OSNR resultante en el punto de combinación, manteniendo fija la potencia de la señal útil. A la salida del splitter, una rama se conectó al OSA (incluyendo un atenuador fijo de 10 dB para evitar potencias de gran magnitud a la entrada del OSA) y la otra rama alimentó el receptor coherente, desde donde se registró el Pre-FEC BER.




Fig. 4.4: Set-up utilizado para caracterizar Pre-FEC BER vs OSNR mediante inyección controlada de ruido ASE.

Esta diferencia es relevante para la interpretación experimental, el OSNR medido con OSA y el OSNR estimado por transceptor no necesariamente coinciden en valor absoluto. Esto se debe a que el OSNR con OSA depende del método de cálculo espectral (ancho de banda de referencia, resolución del instrumento y forma de integración), mientras que el estimado del transceptor depende de la definición interna del DSP (referida al ancho de banda efectivo del receptor y a sus algoritmos de procesamiento). Por lo tanto, es esperable observar un desfase u offset sistemático entre ambas métricas bajo un mismo estado físico del enlace.

En el presente trabajo, el OSA se utilizó para documentar y controlar el barrido de OSNR durante la caracterización mostrada en la Fig. 4.5, mientras que la métrica del transceptor se utiliza posteriormente como entrada del sistema de detección, por ser la medición nativamente disponible en un escenario operacional.




Fig. 4.5: Gráfica Pre-FEC BER vs OSNR para diferentes formatos de modulación. Fuente: Autoría propia.

Los resultados muestran que formatos de menor orden (por ejemplo, DP-QPSK) exhiben menor Pre-FEC BER para un mismo OSNR en comparación con formatos de mayor orden (DP-8QAM y DP-16QAM), reflejando su mayor robustez frente a degradación por ruido.

4.3.3. Potencia Óptica

La potencia óptica de la señal (P) es un parámetro crítico que se monitorea en distintos puntos a lo largo de un enlace óptico, incluyendo la entrada y salida de los amplificadores (EDFA) y la potencia de llegada al receptor. Variaciones en estos niveles de potencia pueden reflejar cambios en el estado físico del enlace, tales como pérdidas anómalas en tramos de fibra o alteraciones en el comportamiento de las etapas de amplificación. Por ello, el monitoreo de potencia constituye una herramienta complementaria para caracterizar la operación del enlace y apoyar el análisis de degradaciones.

La atenuación en la fibra óptica (α) se expresa comúnmente en dB/km, y la potencia de la señal a una distancia L de la fuente ($P(L)$) se relaciona con la potencia de lanzamiento ($P(0)$) mediante:

$$P(L)_{\text{dBm}} = P(0)_{\text{dBm}} - \alpha \cdot L. \quad (4.3)$$

Esta relación evidencia que, a mayor distancia o a mayor coeficiente de atenuación, la potencia disponible disminuye progresivamente. En consecuencia, un aumento de pérdidas respecto al

comportamiento esperado puede manifestarse como una reducción de potencia medida en puntos específicos del enlace.

Por otra parte, el nivel de potencia también se relaciona con el desempeño de la transmisión. Potencias excesivamente bajas tienden a deteriorar la calidad de señal por un menor margen frente al ruido, mientras que potencias elevadas pueden favorecer la aparición de efectos no lineales en la fibra, lo que se asocia a degradaciones progresivas observables en el BER. En este sentido, la potencia constituye una variable relevante para contextualizar y entender condiciones de operación que pueden derivar en degradaciones de QoT.

4.3.3.1. Set-up experimental para potencia de entrada vs Pre-FEC BER

Para caracterizar la relación entre la potencia de lanzamiento a fibra y el Pre-FEC BER, se implementó un set-up con un span de aproximadamente 100 km de fibra monomodo estándar. La Fig. 4.6 muestra el esquema utilizado.

La señal óptica del transmisor (TX) se amplificó mediante un EDFA de tipo booster (EDFA BA) y luego se ajustó con un atenuador variable (VOA), de modo de barrer la potencia de entrada a la fibra en un rango amplio. La señal atenuada se propagó a través de un span de 99.392 km de fibra y, previo a su recepción, se utilizó un EDFA de tipo pre-amplificador (EDFA PA) para asegurar un nivel adecuado de potencia a la entrada del receptor. Para cada valor de potencia de lanzamiento configurado mediante el VOA, se registró el Pre-FEC BER reportado por el receptor coherente.




Fig. 4.6: Set-up experimental para Pre-FEC BER vs Potencia de entrada a fibra. Fuente: Autoría Propia.

En esta investigación, se utilizó este set-up para caracterizar la relación entre el Pre-FEC BER y la potencia de entrada al enlace para distintos formatos de modulación.




Fig. 4.7: Variaciones del Pre-FEC BER a diferentes potencias de entrada al sistema para diferentes formatos de modulación. Fuente: autoría propia.

El experimento muestra que el Pre-FEC BER aumenta tanto a potencias de entrada muy bajas como a potencias de entrada muy altas. A potencias bajas la degradación se asocia principalmente a un menor margen frente al ruido, mientras que a potencias elevadas se relaciona con la aparición de regímenes no lineales en la fibra. En conjunto, estos resultados refuerzan la importancia de comprender el rol de la potencia en la caracterización del estado del enlace y en la interpretación de degradaciones en la QoT.

4.4. Componentes de un enlace óptico

El sistema experimental implementado en el presente trabajo se compone de varios elementos fundamentales típicos de un enlace de comunicaciones ópticas, cuya comprensión es esencial para interpretar la metodología y los resultados obtenidos. En particular, el enlace considerado corresponde a un sistema coherente de 200 km compuesto por dos *spans* de 100 km (S1 y S2), con compensación de pérdidas mediante una cadena de amplificación y con elementos de multiplexación/demultiplexación y control que permiten emular condiciones de operación realistas (incluyendo carga espectral).

4.4.1. Amplificadores de Fibra Dopados con Erblio (EDFA)

Los EDFAs son dispositivos ópticos esenciales en los enlaces de larga distancia y en redes WDM, debido a su capacidad para amplificar señales ópticas directamente, sin necesidad de conversión opto-eléctrica-óptica. En el contexto del laboratorio y la instrumentación disponible, es habitual distinguir dos tipos de EDFAs con funciones diferenciadas:

- **EDFA *Booster* (BA)**: Ubicado generalmente a la salida del transceptor o multiplexor, su función principal es aumentar la potencia de la señal antes de su inyección en la fibra óptica, compensando pérdidas iniciales y maximizando el alcance del enlace.
- **EDFA Pre-amplificador (PA)**: Situado justo antes del receptor, este EDFA amplifica la señal atenuada tras haber recorrido el enlace de fibra, con el objetivo de mejorar el OSNR y asegurar niveles adecuados de potencia para su correcta detección.

Las especificaciones técnicas de ambos tipos de amplificadores se resumen en la Tabla 4.1.

Tabla 4.1: Especificaciones técnicas comparativas de los amplificadores EDFA BA y PA.

Parámetro	EDFA BA	EDFA PA
Ganancia Óptica	11 - 21 dB	20 - 30 dB
Potencia de Entrada	-25 a +7 dBm	-32 a -4 dBm
Potencia de Salida Saturada	$\leq 20dBm$	$\leq 16dBm$
Figura de Ruido	$\leq 5,5dB$	$\leq 5,5dB$
Longitud de Onda	1529 - 1561 nm	
Modo de Funcionamiento	AGC / APC	
Conector Óptico	LC / APC	

De la tabla se desprende que el EDFA Booster está diseñado para manejar un rango de potencias de entrada más alto y entregar una potencia de salida significativamente mayor, lo que es coherente con su función de “refuerzo”. En contraste, el EDFA Pre-amplificador ofrece una ganancia óptica superior y es sensible a señales de entrada más débiles, lo que lo hace adecuado para recuperar la señal antes de la detección.

En el enlace experimental del presente trabajo, la compensación de pérdidas se realiza mediante tres EDFAs (E1–E3): una etapa de lanzamiento (*launch/booster*) E1 para controlar la potencia inyectada al primer *span*, y dos etapas posteriores (E2 y E3) para compensación en línea de las pérdidas de los *spans*. Asimismo, los tres EDFAs se configuran para operar en modo de

control automático de potencia (APC), manteniendo potencia total de salida constante frente a variaciones de potencia de entrada. Este punto es relevante para asegurar condiciones repetibles de potencia de lanzamiento por *span*, lo cual influye en regímenes de degradación asociados a efectos no lineales cuando se emulan condiciones de carga dinámica.

Dentro del contexto del presente trabajo, el mal funcionamiento de un EDFA (por ejemplo, una reducción de ganancia) constituye una condición de degradación considerada. Además, se aprovecha la telemetría disponible de los EDFAs (potencias de entrada y salida por dispositivo) para caracterizar el estado de la cadena de amplificación, información que resulta consistente con la instrumentación y extracción de parámetros planteadas en el enlace.

4.4.2. Wavelength Selective Switches (WSS)

Los WSS son componentes programables que permiten la conmutación, el ruteo y el filtrado selectivo de canales ópticos en un entorno WDM, siendo relevantes para operaciones de multiplexación/demultiplexación y para la gestión flexible del espectro.

El modelo empleado en el laboratorio es un WSS flexible de Finisar¹. Sus especificaciones técnicas más relevantes se resumen en la Tabla 4.2.

Tabla 4.2: Características técnicas relevantes del WSS flexible de Finisar.

Característica	Especificación
Ancho de canal base	12,5 GHz
Capacidad de canales	386 canales @12,5 GHz o 96 canales @50 GHz
Potencia máxima de entrada	27 dBm (total), 9 dBm (por canal de 12,5 GHz)
Pérdida de inserción	2 - 6,5 dB
Tráfico soportado por canal	Hasta 400 Gb/s

En el enlace del presente trabajo se incluyen dos WSS para realizar funciones de multiplexación/demultiplexación. Adicionalmente, se utiliza un esquema de carga espectral basado en una fuente ASE y el primer WSS, el cual permite modelar espectralmente el ASE en “rebanadas” tipo canal adyacente y multiplexarlas con la señal bajo prueba, generando un perfil de carga controlado y repetible alrededor del canal monitoreado. Más allá de condiciones estáticas, el WSS también permite desactivar dinámicamente algunas de estas rebanadas adyacentes, emu-

¹Para una descripción detallada del principio de funcionamiento, la configuración de hardware y los comandos de control del WSS Finisar utilizado, consultar la memoria de título referenciada [29].

lando condiciones tipo *add/drop*. Bajo operación en APC en la etapa de lanzamiento, reducir el número de canales adyacentes activos redistribuye la potencia total entre menos canales, incrementando la potencia por canal y habilitando un régimen de degradación asociado a efectos no lineales.



Fig. 4.8: WSS de Finisar. Fuente: [29].

Dada su función de filtrado, desalineaciones espectrales o fallos en filtros WSS, ya sea por envejecimiento o variaciones de temperatura, pueden causar degradaciones del tipo FS o FT, las cuales no forman parte de los alcances de este trabajo.

4.4.3. Atenuadores Ópticos Variables (VOA)

Los VOAs permiten ajustar de forma controlada la potencia óptica que pasa a través de ellos, introduciendo una atenuación variable en el enlace. En este trabajo, los VOAs se emplean para introducir cambios de atenuación controlados durante la inyección de condiciones de degradación, permitiendo emular escenarios asociados a pérdidas adicionales en tramos del enlace. En coherencia con el diseño experimental, se incorporan VOAs de manera estratégica a lo largo del enlace para habilitar estos cambios de atenuación en condiciones controladas.

4.4.4. Transceptor Coherente

El transceptor coherente Lumentum CFP2-DCO 100G/200G constituye el bloque de transmisión y recepción del enlace. Este dispositivo permite configurar distintos formatos de modulación de doble polarización y, además, extraer métricas monitoreadas directamente en el receptor, tales como el Pre-FEC BER y el OSNR. En el presente trabajo se consideran tres formatos de modulación: DP-QPSK, DP-8QAM y DP-16QAM, lo que permite evaluar el comportamiento de indicadores de QoT bajo regiones de operación distintas según el formato. En la Figura 4.9 se muestran los módulos CFP2-DCO instalados en el módulo programable “Cassini” para la

extracción de datos QoT por medio de conexión SSH.




Fig. 4.9: Transceptores coherentes montados en módulo programable “Cassini”.

4.4.5. Fibra Óptica Monomodo Estándar (SMF)

La SMF es el medio de transmisión predominante en redes ópticas de larga distancia. En el enlace del presente trabajo, la transmisión se realiza sobre dos *spans* de SMF de 100 km (S1 y S2), totalizando 200 km de propagación.

El tipo de fibra más extendido a nivel mundial está estandarizado por la Recomendación G.652 de la Unión Internacional de Telecomunicaciones (UIT) [30]. Específicamente, la fibra utilizada en este trabajo corresponde a la subcategoría G.652.D, caracterizada por ser una fibra de bajo *peak* de agua (*Low Water Peak*). Aunque su ventana de operación principal para sistemas WDM de alta capacidad es la banda C (alrededor de 1550 nm), esta característica la hace compatible con el espectro de 1260 nm a 1625 nm.

Las propiedades ópticas y físicas de la fibra G.652.D se resumen en la Tabla 4.3.

Tabla 4.3: Parámetros típicos de una fibra óptica monomodo estándar según la norma ITU-T G.652.D [30].

Parámetro	Valor Típico (@ 1550 nm)	Unidad
Atenuación	<0.22	dB/km
Dispersión Cromática	~17	ps/(nm·km)
Coefficiente no lineal ((n_2/A_{eff}))	~0.33	($W^{-1}km^{-1}$)
Diámetro de Campo Modal	9.2 - 10.4	(μm)
Coefficiente PMD	$\leq 0,2$	($ps/\sqrt{km}$)

Fenómenos como la atenuación intrínseca de la fibra deben ser compensados por la cadena de amplificación, mientras que pérdidas adicionales y regímenes no lineales inducidos por condiciones de operación pueden reflejarse en degradaciones observables en las métricas monitoreadas.

4.5. Detección y diagnóstico de anomalías

En el ámbito de las redes ópticas, la detección de anomalías se enmarca como la tarea de identificar eventos o patrones que se desvían significativamente del comportamiento normal o esperado del sistema. En el contexto de este trabajo, el objetivo es detectar la presencia de SF, las cuales, al ser degradaciones graduales, pueden manifestarse como anomalías en los parámetros monitoreados del enlace. A nivel conceptual, esta etapa permite discriminar entre operación normal y condiciones anómalas que requieren análisis adicional.

4.5.1. Algoritmos de Aprendizaje No Supervisado para Detección

Para la detección de anomalías, se evaluaron tres algoritmos de aprendizaje no supervisado. La elección de un enfoque no supervisado es particularmente adecuada para este problema, dada la escasez de datos etiquetados de fallas en redes ópticas operativas, donde los eventos anómalos son, por naturaleza, infrecuentes. Estos algoritmos están diseñados para identificar *outliers* o patrones que se desvían de la normalidad, sin necesidad de un entrenamiento previo con ejemplos de fallas.

4.5.1.1. Isolation Forest

Isolation Forest es un método de conjunto (*ensemble*) que opera bajo el principio de que las anomalías son “pocas y diferentes” y, por lo tanto, son más fáciles de aislar que los puntos normales. El algoritmo construye una serie de árboles de decisión aleatorios (*isolation trees*). Como se ilustra en la Figura 4.10, los puntos anómalos (en rojo) tienden a quedar aislados con menos particiones, resultando en un camino promedio más corto desde la raíz del árbol hasta el nodo hoja en comparación con las instancias normales (en azul).




Fig. 4.10: Ilustración del principio de Isolation Forest. Las anomalías son aisladas a menor profundidad en los árboles que las instancias normales. Fuente: [31]

Sus hiperparámetros clave incluyen:

- **n_estimators:** El número de árboles a construir en el "bosque".
- **contamination:** La proporción esperada de anomalías en el conjunto de datos, que ayuda a definir el umbral de decisión para clasificar un punto como anómalo.

4.5.1.2. DBSCAN

DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) es un algoritmo de agrupamiento (*clustering*) basado en la densidad de los datos. Su funcionamiento, ilustrado en la Figura 4.11, se basa en agrupar puntos que están densamente empaquetados y marcar como ruido (o anomalías) aquellos puntos que se encuentran solos en regiones de baja densidad (*outliers*).




Fig. 4.11: Proceso de DBSCAN. A partir de localizaciones moleculares, se definen puntos centrales (core), de borde (boundary) y ruido (outlier) según los parámetros ϵ y MinPts, formando clústeres. Fuente: [32]

Su comportamiento se rige por dos hiperparámetros fundamentales:

- **eps (ϵ):** La distancia máxima entre dos muestras para que una se considere vecina de la otra. Define el radio de vecindad.
- **min_samples:** El número mínimo de muestras en la vecindad de un punto para que este sea considerado un punto central (*core point*).

Estos dos parámetros definen conjuntamente el concepto de “densidad” que el algoritmo utilizará para formar los clústeres.

4.5.1.3. Autoencoder

Un Autoencoder es un tipo de red neuronal artificial utilizada para el aprendizaje no supervisado. Su arquitectura, mostrada en la Figura 4.12, consta de dos partes principales:

- Un **Codificador (Encoder)**, que comprime los datos de entrada (x_i) en una representación latente de menor dimensión ($h(x_i)$), conocida como “cuello de botella”.
- Un **Decodificador (Decoder)**, que intenta reconstruir los datos de entrada originales ($\tilde{x}_i$) a partir de esa representación comprimida.




Fig. 4.12: Arquitectura de un Autoencoder, mostrando las capas de entrada (x_i), el codificador, la capa latente o cuello de botella ($h(x_i)$), el decodificador y la salida reconstruida ($\tilde{x}_i$). Fuente: [33]

El autoencoder se entrena exclusivamente con datos normales, con el objetivo de minimizar el error de reconstrucción. Comúnmente, este error se mide con la función de pérdida de Error Cuadrático Medio (MSE):

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (x_i - \tilde{x}_i)^2 \quad (4.4)$$

Cuando al modelo se le presenta un dato anómalo, es incapaz de reconstruirlo con precisión, lo que resulta en un error de reconstrucción alto. Este error, al superar un umbral, marca la muestra como una anomalía.

4.5.2. Algoritmos de Aprendizaje Supervisado para Diagnóstico de Anomalías

En este trabajo, el diagnóstico se entiende como la capacidad de identificar la causa más probable de una condición anómala observada en el enlace y asociarla a una ubicación dentro de la infraestructura. Desde el punto de vista del aprendizaje automático, esta tarea se modela como un problema de clasificación multiclase, donde un modelo aprende una función $f(\mathbf{x}) \rightarrow y$ que asigna un vector de características $\mathbf{x}$ a una clase y representativa de un tipo de degradación o evento anómalo. El objetivo es que las clases estén definidas de modo que su identificación sea útil para orientar el análisis del enlace.

La localización se aborda como una inferencia posterior basada en la clase estimada: una vez que el modelo asigna una etiqueta, esta se interpreta mediante un mapeo predefinido

clase→componente/segmento, de modo que el diagnóstico entregue no solo qué ocurrió, sino también dónde es más probable que se haya originado. En este marco, el desempeño depende de la capacidad del clasificador para separar clases potencialmente cercanas en el espacio de características, lo que motiva comparar modelos con distintas propiedades de representación y generalización.

A continuación se describen tres familias de modelos supervisados utilizados para clasificación multiclase: (i) métodos basados en ensambles de árboles, como Random Forest, que construyen fronteras de decisión mediante particiones sucesivas del espacio; (ii) modelos basados en margen, como SVM, que buscan separaciones con máximo margen (lineales o no lineales según el kernel); y (iii) modelos basados en redes neuronales feed-forward, como MLP, que aprenden transformaciones no lineales mediante capas y funciones de activación.

4.5.2.1. Random Forest

Random Forest es un método supervisado basado en un ensamble de árboles de decisión. El modelo construye múltiples árboles a partir de subconjuntos de los datos y de las variables de entrada, y combina sus predicciones mediante votación. Esta estrategia permite capturar relaciones no lineales y reduce la varianza respecto a un único árbol, lo que lo hace adecuado para problemas de clasificación con características tabulares.




Fig. 4.13: Esquema conceptual de Random Forest. Fuente: [34]

Sus hiperparámetros más relevantes incluyen:

- **n_estimators**: número de árboles del ensamble.
- **max_depth**: profundidad máxima (controla complejidad).

- **min_samples_split** / **min_samples_leaf**: regularización por tamaño mínimo.
- **max_features**: número de variables consideradas en cada división.

4.5.2.2. Support Vector Machine (SVM)

SVM es un clasificador supervisado que busca separar clases mediante un hiperplano que maximiza el margen entre ellas. Cuando los datos no son separables linealmente, puede utilizar funciones *kernel* para modelar fronteras de decisión no lineales.




Fig. 4.14: Esquema conceptual de SVM. Fuente: [34]

Sus hiperparámetros clave incluyen:

- **C**: penalización por error (margen vs clasificación).
- **kernel**: tipo de kernel (por ejemplo, lineal, RBF).
- γ : parámetro asociado a kernels como RBF (alcance de influencia).

4.5.2.3. Multi-Layer Perceptron (MLP)

MLP es una red neuronal *feed-forward* compuesta por una capa de entrada, una o más capas ocultas y una capa de salida. A través de funciones de activación no lineales y entrenamiento por retropropagación, MLP puede aproximar relaciones complejas entre variables de entrada y clases.




Fig. 4.15: Esquema conceptual de MLP. Fuente: [35]

Sus elementos e hiperparámetros más relevantes incluyen:

- **Arquitectura:** número de capas ocultas y neuronas por capa.
- **Función de activación:** introduce no linealidad (por ejemplo, ReLU).
- **Optimizador y tasa de aprendizaje:** controlan el proceso de entrenamiento.
- **Regularización:** por ejemplo, penalización L2 y/o *dropout*.

4.5.3. Preprocesamiento en Machine Learning

El éxito de cualquier modelo de ML depende en gran medida de la calidad y preparación de los datos de entrada. En el contexto de datos de series temporales provenientes del monitoreo de enlaces ópticos, el preprocesamiento permite transformar los datos brutos en características que resuman el comportamiento del enlace y faciliten el aprendizaje de patrones asociados a operación normal y condiciones anómalas.

4.5.3.1. Ingeniería de Características

La ingeniería de características es el proceso de utilizar el conocimiento del dominio para crear nuevas variables (features) a partir de los datos brutos, con el fin de simplificar y mejorar el rendimiento del modelo de aprendizaje. En lugar de alimentar al modelo con una larga secuencia de datos temporales, a menudo es más efectivo extraer características estadísticas que resuman el comportamiento de la señal en ventanas de tiempo definidas.

Para una serie temporal de un parámetro P (como el BER o el OSNR) dentro de una ventana, se pueden calcular descriptores estadísticos como:

- **Media (μ):** Representa el valor promedio del parámetro en la ventana, indicando su nivel central.
- **Desviación Estándar (σ):** Mide la dispersión o variabilidad del parámetro, indicando su estabilidad.
- **Valores Máximos y Mínimos:** Capturan los picos y valles extremos del comportamiento.

Este proceso condensa la información temporal en un conjunto de características descriptivas que pueden ser más fácilmente interpretadas por los algoritmos de ML para identificar patrones anómalos.

4.5.3.2. Normalización de Características

La normalización es un paso crítico cuando las características de entrada tienen diferentes escalas y rangos (e.g., OSNR en [dB] y BER en escala lineal). Los algoritmos sensibles a la magnitud de las características, como las redes neuronales o los basados en distancia, pueden ser dominados por aquellas con valores más grandes. La normalización ajusta todas las características a una escala común. Dos métodos comunes son:

- **Normalización Min-Max (Min-Max Scaling):** Re-escala los datos a un rango fijo, comúnmente $[0, 1]$ o $[-1, 1]$. La fórmula para escalar a $[0, 1]$ es:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (4.5)$$

Donde $X_{\min}$ y $X_{\max}$ son los valores mínimo y máximo de la característica en el conjunto de datos de entrenamiento.

- **Estandarización (Z-score Normalization):** Transforma los datos para que tengan una media de 0 y una desviación estándar de 1. La fórmula es:

$$X_{\text{stand}} = \frac{X - \mu}{\sigma} \quad (4.6)$$

Donde μ es la media y σ es la desviación estándar de la característica. Este método es robusto a la presencia de outliers.

La aplicación de estas técnicas es fundamental para garantizar que el proceso de aprendizaje del modelo sea estable y que los patrones aprendidos sean generalizables y robustos.

4.6. Métricas de evaluación

El rendimiento de los modelos se evalúa mediante métricas estándar basadas en la matriz de confusión. En este trabajo, se consideran métricas aplicables tanto a la detección (clasificación binaria) como al diagnóstico (clasificación multiclase), utilizando precisión, *recall* y F1-score, junto con matrices de confusión.

4.6.1. Métricas para detección (clasificación binaria)

En clasificación binaria, se definen:

- **VP**: verdaderos positivos (condiciones anómalas correctamente detectadas).
- **VN**: verdaderos negativos (condiciones normales correctamente identificadas).
- **FP**: falsos positivos (condición normal marcada como anómala).
- **FN**: falsos negativos (condición anómala no detectada).

A partir de estas cantidades, se definen las siguientes métricas:

$$\text{Precisión} = \frac{\text{VP}}{\text{VP} + \text{FP}} \quad (4.7)$$

$$\text{Recall} = \frac{\text{VP}}{\text{VP} + \text{FN}} \quad (4.8)$$

$$\text{F1-score} = 2 \cdot \frac{\text{Precisión} \cdot \text{Recall}}{\text{Precisión} + \text{Recall}} \quad (4.9)$$

4.6.2. Métricas para diagnóstico (clasificación multiclase)

En clasificación multiclase, el desempeño se analiza mediante la matriz de confusión y métricas por clase. Para cada clase k , se definen cantidades *uno-contra-el-resto*:

$$\text{VP}_k = C_{kk} \quad (4.10)$$

$$\text{FP}_k = \sum_{i \neq k} C_{ik} \quad (4.11)$$

$$\text{FN}_k = \sum_{j \neq k} C_{kj} \quad (4.12)$$

donde C_{ij} corresponde al número de muestras cuya clase real es i y que fueron predichas como j .

Con estas cantidades, las métricas por clase se calculan como:

$$\text{Precisión}_k = \frac{\text{VP}_k}{\text{VP}_k + \text{FP}_k} \quad (4.13)$$

$$\text{Recall}_k = \frac{\text{VP}_k}{\text{VP}_k + \text{FN}_k} \quad (4.14)$$

$$\text{F1-score}_k = 2 \cdot \frac{\text{Precisión}_k \cdot \text{Recall}_k}{\text{Precisión}_k + \text{Recall}_k} \quad (4.15)$$

El análisis del diagnóstico se reporta mediante matrices de confusión multiclase y métricas por clase, permitiendo identificar el desempeño diferencial entre tipos de eventos anómalos.

5. Implementación experimental y resultados

El presente capítulo se dedica a detallar el desarrollo práctico y la implementación de la metodología del trabajo, demostrando cómo cada objetivo específico fue alcanzado mediante un riguroso proceso experimental y analítico. Se abordará la configuración del entorno experimental, la automatización de la recolección de datos, el preprocesamiento de la información obtenida, y la implementación de los modelos de detección y diagnóstico.

5.1. Diseño e implementación del enlace óptico experimental para realizar las mediciones en diferentes condiciones de operación.

La consecución de este primer objetivo fue fundamental para establecer el entorno controlado y representativo necesario para este trabajo. Se diseñó e implementó un *set-up* experimental que emula un enlace de comunicación óptica de larga distancia, específicamente de 200 km, en las instalaciones del Laboratorio de Optoelectrónica de la Universidad de Concepción. El diseño de este enlace fue concebido para replicar condiciones de un sistema de comunicación realista y permitir la inducción controlada de SF.

El núcleo del sistema se articuló alrededor de un transceptor coherente Lumentum CFP2-DCO 100G/200G *Pluggable Transceiver*, seleccionado por su capacidad de operar con diferentes formatos de modulación coherente y por ser utilizado en investigaciones previas[36]. En particular, el enlace se configuró para operar con DP-QPSK, DP-8QAM y DP-16QAM, lo que permite evaluar el comportamiento del sistema frente a cambios de formato de modulación, un factor relevante en entornos de red dinámicos.

El enlace se configuró con dos *spans* de fibra monomodo estándar (SMF) de 100 km cada uno, totalizando 200 km de fibra óptica. La compensación de las pérdidas inherentes a la transmisión a través de estos tramos de fibra se realizó mediante EDFAs. La arquitectura del enlace, como se ilustra en la Figura 5.1, incluyó una serie de componentes interconectados para simular un sistema de comunicación robusto:

- Dos WSS para funciones de multiplexación y demultiplexación (MUX/DEMUX).
- Un EDFA (E1) *Booster Amplifier* (BA) encargado de controlar la potencia de la señal a la entrada del enlace.
- Dos EDFA (E2-E3) *Pre-Amplifier* (PA) operando en modo APC, de modo de mantener condiciones repetibles de potencia de salida frente a variaciones de potencia de entrada.
- Dos Atenuadores Ópticos Variables (VOA) estratégicamente posicionados para permitir la simulación de escenarios de falla específicos.




Fig. 5.1: Diagrama del enlace óptico experimental de 200 km implementado. Fuente: Autoría Propia.

Un aspecto distintivo y fundamental del diseño fue la simulación de un entorno *Wavelength Division Multiplexing* (WDM) con un espaciado de canales estándar de 100 GHz. Dada la limitación de contar con un único canal modulado por un transceptor comercial, se adoptó una estrategia para simular la presencia de canales adyacentes mediante la generación y manipulación de ruido de emisión espontánea amplificada (ASE), tal como se propone en la literatura [25]. Esta estrategia permitió evaluar la robustez del sistema en un escenario más realista donde la interferencia entre canales es un factor presente y relevante para el rendimiento de la red.

El diseño del enlace, como se observa en la Figura 5.1, se compone de dos partes principales en su implementación:

1. **Generación de Ruido ASE y multiplexación simulada:** Un EDFA de la marca Thorlabs, seguido de un EDFA amplificador de arranque (*Booster Amplifier* - EDFA BA), se utilizó para generar un piso de ruido ASE. Este ruido espectral fue posteriormente moldeado por un WSS para simular la presencia de múltiples canales ópticos adyacentes. El canal óptico real, proveniente del transceptor, también fue introducido en este WSS, resultando en un espectro multiplexado que incluyó el canal de interés y los canales simulados.
2. **Enlace de 200 km:** La señal multiplexada atraviesa un EDFA BA, seguido de un *span*

de fibra óptica SMF de 100 km y un atenuador óptico variable (VOA). Posteriormente, la señal es amplificada por un pre-amplificador (EDFA Pre-Amplifier - EDFA PA), atraviesa otro *span* de fibra de 100 km y otro VOA, antes de ser amplificada por un último EDFA PA justo antes del segundo WSS. Este último WSS se utiliza para filtrar el canal óptico de interés, eliminando los canales simulados generados por ruido ASE, antes de que la señal llegue al receptor óptico.

Además de permitir la inyección controlada de escenarios normales y de falla, el enlace fue diseñado para habilitar el monitoreo de variables consistentes con el pipeline del trabajo. En el receptor se registran indicadores de QoT (Pre-FEC BER y OSNR) y, en paralelo, se dispone de telemetría de potencia óptica a lo largo de la cadena de amplificación.

La viabilidad de este diseño es fundamental, ya que cubre tanto la simulación de las fallas propuestas como la capacidad de extraer la información necesaria para el análisis.

5.1.1. Equipamiento Experimental

La implementación del enlace óptico y la recolección de datos se llevaron a cabo utilizando una serie de instrumentos de laboratorio especializados, integrados en un *rack* de comunicaciones para su gestión eficiente y control. A continuación, se presenta un listado de los principales equipos utilizados y su función en el experimento (Ver Tabla 5.1).

Tabla 5.1: Listado de instrumentos utilizados en el experimento

Instrumento/Modelo	Función Principal
AS7716-24SC Cassini (Switch Coherente)	Conexión con transceptores
2x Lumentum CFP2-DCO 100G/200G	Transceptor coherente (TX/RX)
Chasis M6200-CH2U	Chasis para módulos EDFA y VOA
EDFA Thorlabs 100S	Generación de ruido ASE
EDFA <i>Booster Amplifier</i> M6200-20BA	Amplificación de señal (inicial)
2x EDFA <i>Pre-Amplifier</i> M6200-25PA	Amplificación de señal (en la línea - antes del receptor)
2x VOA M6200-SFPVOA	Atenuación variable
2x Fibra Óptica SMF G652D (100km c/u)	Medio de transmisión
2x 1x9 Flexgrid WSS / Finisar	MUX/DEMUX, Moldeado de espectro ASE
8x <i>Jumpers</i> de fibra óptica (~ 0.3 dB ATT)	Interconexión del enlace

La infraestructura experimental completa se montó en un *rack* óptico, lo que permitió una organización eficiente del cableado de fibra y los equipos electrónicos, minimizando la pérdida de señal y facilitando el monitoreo. Una vista general del *rack* y la interconexión de los componentes se muestra en la Figura 5.2.




Fig. 5.2: Vista general del *set-up* experimental montado en el Laboratorio de Optoelectrónica. Fuente: Autoría propia.

Para la simulación de SF, la metodología experimental implicó la inducción controlada de cuatro estados operativos distintos: un estado normal y tres tipos de SF. Las características y la implementación específica de cada falla se detallan en la Tabla 5.2, y se describen a continuación:

Tabla 5.2: Detalles de implementación de los escenarios de falla

Estado de Falla	Acción de Implementación
Ganancia reducida EDFA	Reducción de ganancia de aproximadamente 4–5 dB en un único EDFA.
Atenuación en el <i>span</i>	Aumento de atenuación de aproximadamente 4–5 dB en un único VOA.
Interferencia no lineal (NLI)	Reducción de canales activos (carga dinámica).

- **Ganancia Reducida en EDFA:** Esta SF, representativa del envejecimiento de los componentes, se simuló mediante una reducción controlada de aproximadamente 4 a 5 dB en la ganancia de uno de los EDFAs del enlace. Esta acción se implementó ajustando programáticamente la ganancia individual del amplificador afectado, replicando una disminución en su eficiencia de amplificación (por ejemplo, asociada a una disminución en la corriente de bombeo).
- **Atenuación en el *Span*:** Para emular la degradación de la fibra óptica por antigüedad o la inclusión de dispositivos pasivos que introducen pérdidas adicionales, se indujo un aumento de atenuación de aproximadamente 4 a 5 dB en uno de los VOAs ubicados dentro del enlace. Estos atenuadores, situados estratégicamente después de cada tramo de fibra de 100 km, permitieron introducir una pérdida de potencia controlada en la señal óptica.
- **Interferencia No Lineal (NLI):** La degradación asociada a NLI fue inducida aprovechando la operación en APC del EDFA BA. Al desactivar canales WDM adyacentes a la señal de interés (para emular una condición de baja carga), la potencia total de salida del EDFA se redistribuye entre los canales activos restantes. Este fenómeno aumenta la potencia por canal y empuja la propagación hacia un régimen donde los efectos no lineales en la fibra se vuelven dominantes.

En particular, el primer WSS permite moldear espectralmente el ASE en rebanadas tipo canal adyacente y activar/desactivar dichas rebanadas para emular condiciones tipo add/drop. Bajo operación en APC en la etapa de lanzamiento, reducir el número de canales adyacentes activos redistribuye la potencia total entre menos canales, incrementando la potencia por canal y habilitando un régimen de degradación asociado a efectos no lineales.

Para efectos de análisis posterior, las condiciones de ganancia reducida y de atenuación adicional se inducen en más de una ubicación del enlace, lo que permite definir clases diferenciadas por

localización (por ejemplo, asociadas a etapas de amplificación específicas y a *spans* específicos). En cambio, el régimen dominado por efectos no lineales se trata como una condición diferenciada asociada a escenarios de carga dinámica.

El diseño permite la extracción y configuración de los parámetros definidos en esta propuesta. Los parámetros de funcionamiento de cada uno de los EDFAs y VOAs pueden ser establecidos mediante la implementación de un código que interactúe con las interfaces de control de estos dispositivos. De manera similar, el receptor óptico utilizado permite la extracción del PRE-FEC BER, el OSNR y la potencia óptica de entrada a este.

5.1.2. Parámetros de Operación del Enlace

Para caracterizar el comportamiento “normal” del enlace y establecer la línea base para la simulación de SF, este se configuró con los siguientes parámetros de operación.

Tabla 5.3: Parámetros de Operación del Enlace en Estado Normal


Parámetro	Valor/Configuración
Formato de modulación	DP-QPSK, DP-8QAM y DP-16QAM
Potencia de salida del transmisor	0 dBm
λ del transmisor (nm)	1550.1
λ canales adyacentes (nm)	1547.7 - 1548.5 - 1549.3 - 1550.9 - 1551.7 - 1552.5
Ganancia EDFA BA	17 - 18 dB de manera aleatoria por ventana de 60 s
Ganancia 1 ^{er} EDFA PA	19 - 20 dB de manera aleatoria por ventana de 60 s
Ganancia 2 ^{do} EDFA PA	15 - 16 dB de manera aleatoria por ventana de 60 s
Atenuación de los VOA	0.0 - 1.0 dB de manera aleatoria por ventana de 60 s

Estos parámetros sirvieron como el punto de referencia para las mediciones de BER, OSNR y potencia en el estado sin fallas, y para la caracterización de los rangos de operación.

5.2. Método automatizado para la extracción de datos

La implementación de un método automatizado para la extracción de datos fue un paso importante para asegurar una recolección sistemática, eficiente y trazable de la información necesaria para el análisis. Este desarrollo se basó en scripts programados en Python, permitiendo la interacción programática con los distintos dispositivos del set-up experimental y reduciendo la dependencia de procedimientos manuales durante campañas extensas de medición.

La comunicación con los módulos Cassini que alojan los transceptores (TX/RX) se estableció mediante Secure Shell (SSH). Si bien el acceso manual se realizaba tradicionalmente mediante PuTTY y comandos de terminal, la automatización se implementó mediante la librería Paramiko en Python. Esto permitió ejecutar remotamente comandos de consulta (por ejemplo, `show coherent-module 3`) para leer parámetros de la señal en el receptor, incluyendo Pre-FEC BER, OSNR y la potencia óptica de entrada al receptor. De forma análoga, mediante SSH y comandos específicos (ver Anexo X), fue posible configurar programáticamente parámetros del transceptor tales como potencia de salida del láser, frecuencia de operación y formato de modulación.



```

10.100.2.102 - PuTTY
login as: ocnos
ocnos@10.100.2.102's password:
Linux LAB-CAS-MPLS-02 4.19.91-g3926df645 #1 SMP Thu Nov 4 05:20:09 UTC 2021 x86_64
Last login: Thu Feb 14 10:15:46 2019 from 10.100.2.3

OcnOS version EC_AS7716-24SC-OcnOS-5.0.187-OTN_MPLS-S0-P0 11/29/2021 09:14:18
LAB-CAS-MPLS-02>enable
LAB-CAS-MPLS-02#config t
Enter configuration commands, one per line. End with CNTL/Z.
LAB-CAS-MPLS-02(config)#coherent-module 3
LAB-CAS-MPLS-02(config-module)#network-interface 0
LAB-CAS-MPLS-02(config-netif)#tx-output-power 2
LAB-CAS-MPLS-02(config-netif)#commit
LAB-CAS-MPLS-02(config-netif)#end
  
```

Fig. 5.3: Ejemplo de inicio de sesión y configuración de potencia de salida del transceptor de manera manual mediante PuTTY. Fuente: Autoría propia.

La gestión y adquisición de datos de los EDFAs y los VOAs se realizó mediante la interfaz del software NMS Server, el cual se comunica con el chasis M6200-CH2U que contiene estos módulos. La automatización de estas interacciones (ver Anexo X) se implementó mediante solicitudes HTTP tipo POST utilizando la librería `requests` de Python, dirigidas a la API del NMS Server. Esto permitió monitorear en tiempo real las potencias de entrada y salida de cada EDFA, y además configurar de manera programática los valores de ganancia de los EDFAs y los niveles de atenuación de los VOAs. En la implementación, los EDFAs se identificaron por ranura en el chasis (Slot1, Slot3, Slot4 para EDFA1, EDFA2 y EDFA3 respectivamente), manteniendo

consistencia entre telemetría, configuración y registro de datos.




Fig. 5.4: Ejemplo de configuración manual de un EDFA PA. Fuente: Autoría propia.

Para la comunicación con los WSS se utilizó una Raspberry Pi conectada a la misma red local que el computador principal. La Raspberry Pi estaba conectada al WSS mediante RS-232, y la automatización se implementó accediendo vía SSH a la Raspberry Pi y ejecutando comandos de terminal (por ejemplo, utilizando `minicom`) para controlar la configuración del WSS. Este esquema permitió integrar el control de la carga espectral dentro del mismo procedimiento automatizado de medición.

El proceso de adquisición se estructuró en fases de muestreo asociadas a un estado operativo específico del enlace (condición normal o condición de falla). En cada fase, los parámetros configurables del set-up (por ejemplo, ganancias de EDFAs y atenuaciones de VOAs) se ajustaron dentro de rangos de operación definidos, con el objetivo de introducir variabilidad controlada y representar condiciones de operación realistas. Durante cada fase, las variables de interés se registraron con una frecuencia de muestreo de 1 Hz, quedando almacenadas como series temporales crudas.

El almacenamiento se realizó en archivos CSV, incorporando para cada lectura una marca de tiempo, el segundo relativo dentro del bloque de medición, y los valores de los parámetros consultados. Adicionalmente, se incluyó un identificador de condición (`id_falla`) para etiquetar la operación normal y las distintas condiciones anómalas generadas durante la adquisición. Estos registros crudos constituyen la base para el preprocesamiento posterior, donde se realiza el ventaneo temporal y la construcción de muestras a nivel ventana (descrito en la sección siguiente).

Un extracto de las primeras lecturas de estos registros crudos se presenta en la Tabla 5.4. La tabla ilustra el formato de los datos almacenados por segundo, mostrando las variables principales obtenidas desde el receptor y el identificador de condición asociado a la medición. La columna “Seg” indica el segundo de la lectura dentro del bloque de muestreo.

Tabla 5.4: Extracto de muestras iniciales de estados normales (ID_Falla 0) para los formatos de modulación DP-QPSK y DP-16-QAM, relevantes para la detección de SF.

Timestamp	Seg	PRE-FEC BER	OSNR	P_{in} P_{out} $EDFA_{1,2,3}$	ID Falla
DP-QPSK					
2025-05-22T11:56:52.576	0	1.646230e-09	27.00	-9 11 -8 9 -12 4	0
2025-05-22T11:56:53.704	1	8.231151e-10	26.60	-9 11 -8 9 -12 4	0
2025-05-22T11:56:54.813	2	8.231151e-10	27.30	-9 11 -8 9 -12 4	0
DP-8QAM					
2025-06-06T13:54:06.384	0	1.518352e-03	22.51	-9 11 -8 9 -12 4	0
2025-06-06T13:54:07.458	1	1.152554e-03	22.56	-9 11 -8 9 -12 4	0
2025-06-06T13:54:08.538	2	1.715236e-03	22.54	-9 11 -8 9 -12 4	0
DP-16QAM					
2025-06-06T13:54:06.384	0	2.406705e-03	27.80	-9 11 -8 9 -12 4	0
2025-06-06T13:54:07.458	1	2.381303e-03	27.80	-9 11 -8 9 -12 4	0
2025-06-06T13:54:08.538	2	2.422804e-03	27.80	-9 11 -8 9 -12 4	0

5.3. Preprocesamiento y aplicación de algoritmos de Machine Learning para la detección de soft-failures.

En esta sección se describe el procesamiento aplicado a los registros adquiridos y la implementación de la etapa de detección del pipeline en cascada. El objetivo es transformar las series temporales medidas en el receptor en un conjunto de características compactas y estables, y evaluar modelos de detección de anomalías entrenados únicamente con operación normal.

5.3.1. Ventaneo temporal y construcción de muestras

Los parámetros de QoT medidos en el receptor (Pre-FEC BER y OSNR) se registraron con resolución temporal de 1 s y luego se segmentaron en ventanas de 60 s, de modo que cada ventana contiene $N = 60$ muestras consecutivas. Para cada ventana y para cada variable $x \in \{\text{BER}, \text{OSNR}\}$ se calcularon estadísticos muestrales que resumen el comportamiento del enlace en dicho intervalo:

$$\mu_x = \frac{1}{N} \sum_{i=1}^N x_i, \quad (5.1)$$

$$\sigma_x = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu_x)^2}. \quad (5.2)$$

La Tabla 5.5 muestra un ejemplo del formato final a nivel de ventana. En esta tabla se incluyen, además, promedios de telemetría de potencias en la cadena de amplificación (que se utilizan posteriormente en diagnóstico). Sin embargo, para detección se emplean únicamente las características derivadas de Pre-FEC BER y OSNR (ver Subsección 5.3.3).

Tabla 5.5: Ejemplo de estructura del dataset por ventana (60 s): características de QoT y telemetría de potencias.

<i>id_failure</i>	Clase	Cantidad
0	Operación normal	500
1	Ganancia reducida en E1	250
2	Ganancia reducida en E2	250
3	Atenuación Adicional en S1	250
4	Atenuación Adicional en S2	250
5	Degradación por NLI	500

Como ejemplo de la estructura resultante de los datos después de la ingeniería de características, la Tabla 5.6 muestra un extracto de tres muestras transformadas, por formato de modulación, ilustrando cómo cada ventana de 60 segundos de mediciones se convierte en una única fila con características numéricas:

Tabla 5.6: Muestras representativas a nivel de ventana del conjunto de datos construido (DP-QPSK, DP-8QAM y DP-16QAM). Pre-FEC BER es adimensional; el OSNR se expresa en dB; y las potencias de los EDFAs se expresan en dBm. Cada fila corresponde a una ventana de 60 s resumida mediante la media (μ) y la desviación estándar (σ) de los indicadores de QoT, así como las potencias medias de entrada y salida del EDFA.

<i>id_failure</i>	Pre-FEC BER _(μ)	Pre-FEC BER _(σ)	OSNR _(μ)	OSNR _(σ)	E1 $P_{in(\mu)}$	E1 $P_{out(\mu)}$	E2 $P_{in(\mu)}$	E2 $P_{out(\mu)}$	E3 $P_{in(\mu)}$	E3 $P_{out(\mu)}$
	(-)	(-)	(dB)	(dB)	(dBm)	(dBm)	(dBm)	(dBm)	(dBm)	(dBm)
DP-QPSK										
0	$2,812 \times 10^{-9}$	$9,24 \times 10^{-10}$	27.10	0.3793	-9.518	11.894	-8.995	9.313	-12.343	4.021
1	$4,715 \times 10^{-9}$	$1,87 \times 10^{-9}$	25.82	0.3296	-9.530	5.811	-15.166	9.470	-12.158	4.032
2	$7,735 \times 10^{-9}$	$2,77 \times 10^{-9}$	25.51	0.3450	-9.588	11.310	-9.585	4.940	-16.842	4.026
3	$5,761 \times 10^{-9}$	$2,07 \times 10^{-9}$	25.84	0.3312	-9.599	11.100	-14.539	9.600	-12.040	4.023
DP-8QAM										
0	$1,518 \times 10^{-3}$	$9,96 \times 10^{-5}$	22.51	0.3323	-6.234	11.943	-11.193	9.100	-20.120	5.229
1	$1,896 \times 10^{-3}$	$9,31 \times 10^{-5}$	22.04	0.3930	-6.234	5.015	-18.003	9.911	-19.750	5.765
2	$1,764 \times 10^{-3}$	$8,69 \times 10^{-5}$	22.18	0.3078	-6.210	11.090	-12.139	4.376	-24.960	5.933
3	$1,855 \times 10^{-3}$	$1,03 \times 10^{-4}$	22.08	0.3486	-6.226	11.588	-16.638	9.877	-19.746	5.762
DP-16QAM										
0	$2,354 \times 10^{-3}$	$1,06 \times 10^{-4}$	28.20	0.5958	-10.261	11.620	-9.210	9.390	-12.237	4.027
1	$3,770 \times 10^{-3}$	$1,74 \times 10^{-4}$	25.99	0.5387	-8.086	6.004	-14.910	9.700	-11.926	4.027
2	$4,674 \times 10^{-3}$	$2,00 \times 10^{-4}$	24.98	0.3702	-7.951	11.100	-9.760	4.830	-16.948	3.971
3	$3,571 \times 10^{-3}$	$1,66 \times 10^{-4}$	26.23	0.5349	-7.939	11.230	-14.410	9.300	-12.322	3.975

5.3.2. Tratamiento de lecturas anómalas dentro de la ventana

Durante la adquisición se observaron casos puntuales de lecturas inconsistentes dentro de una ventana (por ejemplo, valores fuera de rango o lecturas espurias asociadas al proceso de extracción). En lugar de descartar la ventana completa, estas lecturas se ajustaron utilizando el promedio de las variables, con el fin de evitar que un número reducido de puntos anómalos distorsione el resumen estadístico de la ventana.

En particular, para cada ventana y cada variable, cuando una muestra x_i fue marcada como inconsistente, se reemplazó por el valor μ_x estimado para dicha ventana (o por un promedio calculado excluyendo los puntos marcados, cuando correspondió). Este criterio mantiene el tamaño de ventana constante y estabiliza el cálculo de características sin eliminar muestras completas.

5.3.3. Selección de características para detección

Inicialmente se consideró utilizar $(\mu_{\text{BER}}, \sigma_{\text{BER}}, \mu_{\text{OSNR}}, \sigma_{\text{OSNR}})$ como entrada de la etapa de detección. Para analizar redundancias entre estas variables se calculó la matriz de correlación mostrada en la Fig. 5.5.




Fig. 5.5: Matriz de correlación de características candidatas para detección. Fuente: Autoría propia.

El análisis evidencia alta redundancia entre el promedio y la desviación estándar de Pre-FEC BER (correlación ≈ 1), y una correlación elevada entre el promedio y la desviación estándar de OSNR. En consecuencia, y para reducir dimensionalidad sin perder información relevante, se descartaron σ_{BER} y σ_{OSNR} , dejando como vector de entrada de detección únicamente:

$$\mathbf{x} = [\mu_{\text{BER}}, \mu_{\text{OSNR}}]. \quad (5.3)$$

Esta elección también mantiene coherencia con el objetivo operacional de detección temprana usando indicadores de QoT observables en el receptor.

5.3.4. Normalización por formato y clipping

Para permitir comparabilidad entre ventanas y estabilizar el entrenamiento, se aplicó normalización min-max con rango objetivo $[-1, 1]$. Dado que las distribuciones de BER/OSNR dependen del formato de modulación, la normalización se realizó por formato, estimando mínimos y máximos a partir de un subconjunto de calibración del formato correspondiente. Además, en la fase de aplicación se utilizó clipping para limitar valores fuera del rango observado durante la calibración y durante la posterior evaluación con el set de pruebas.

Para una característica escalar x , la transformación se definió como:

$$x_{\text{clip}} = \min(\max(x, x_{\text{mín}}), x_{\text{máx}}), \quad (5.4)$$

$$x_{\text{sc}} = 2 \cdot \frac{x_{\text{clip}} - x_{\text{mín}}}{x_{\text{máx}} - x_{\text{mín}}} - 1. \quad (5.5)$$

5.3.5. Selección del formato de referencia para entrenamiento (DP-QPSK)

El entrenamiento inicial del detector se realizó usando operación normal del formato DP-QPSK como referencia. El criterio es que DP-QPSK presenta una variabilidad más amplia en el comportamiento conjunto Pre-FEC BER-OSNR bajo cambios operacionales, entregando un patrón normal más informativo para el aprendizaje del detector. Esto es consistente con la evidencia experimental presentada previamente en la figura 4.5 (relación BER vs OSNR por formato).

5.3.6. Modelos evaluados para detección y criterio de selección

La detección se formuló como un problema de una clase: los modelos se entrenaron únicamente con ventanas de operación normal y luego se evaluó su capacidad para discriminar entre condición normal y anómala. Se compararon tres enfoques no supervisados: Isolation Forest, DBSCAN y un Autoencoder.

La Tabla 5.7 resume el desempeño comparativo de los tres modelos en DP-QPSK, utilizando precisión, recall y F1-score para la clase anómala. En base a estos resultados, se seleccionó el autoencoder como modelo final de detección.

Tabla 5.7: Comparación de modelos de detección en DP-QPSK (conjunto de evaluación).

Modelo	Precisión	Recall	F1-score
Isolation Forest	1.00	0.83	0.91
DBSCAN	0.92	0.92	0.92
Autoencoder	1.00	1.00	1.00

5.3.7. Calibración operacional del umbral de decisión (autoencoder)

Una vez entrenado el autoencoder con operación normal, cada ventana se evalúa mediante el error de reconstrucción:

$$s_{\text{AE}}(\mathbf{x}) = \|\mathbf{x} - \hat{\mathbf{x}}\|^2, \quad (5.6)$$

donde $\hat{\mathbf{x}}$ es la reconstrucción generada por el modelo.

La decisión binaria se obtiene mediante umbral:

$$\hat{y}(\mathbf{x}) = \begin{cases} 0, & s_{\text{AE}}(\mathbf{x}) \leq \tau, \\ 1, & s_{\text{AE}}(\mathbf{x}) > \tau, \end{cases} \quad (5.7)$$

donde $\hat{y} = 0$ indica condición normal y $\hat{y} = 1$ indica condición anómala.

En la siguiente sección, se mostrará cómo el umbral τ se calibró para poder evaluar este modelo en diferentes formatos de modulación, usando exclusivamente ventanas normales del subconjunto de calibración, fijándolo como el percentil 99 de la distribución de s_{AE} en condición normal:

$$\tau = P_{99}(s_{\text{AE}}(\mathbf{x}) \mid \hat{y} = 0). \quad (5.8)$$

Este criterio evita utilizar muestras de falla para ajustar el umbral y aproxima un modo de operación real, donde típicamente se dispone principalmente de datos normales para calibración.

5.3.8. Resultados de detección: evaluación in-format y transferencia por formato

Con el modelo seleccionado, se reportó el desempeño del autoencoder tanto en DP-QPSK (in-format) como al aplicar el mismo detector en DP-8QAM y DP-16QAM. En la transferencia por formato, se mantuvo fijo el modelo entrenado y se calibraron únicamente los parámetros de normalización y el umbral τ usando un subconjunto normal de calibración del formato objetivo, siguiendo el mismo criterio P99.

La Fig. 5.6 presenta una visualización conjunta de las matrices de confusión (una por formato) para el esquema de entrenamiento base (DP-QPSK) y evaluación sobre DP-QPSK, DP-8QAM y DP-16QAM.




Fig. 5.6: Matrices de confusión para detección con entrenamiento base DP-QPSK y evaluación en (a) DP-QPSK, (b) DP-8QAM y (c) DP-16QAM. Fuente: Autoría propia.

La Tabla 5.8 resume las métricas reportadas para cada formato.

Tabla 5.8: Desempeño del autoencoder en detección por formato (transferencia con recalibración por formato).

Formato (evaluación)	Precisión	Recall	F1-score
DP-QPSK	1.00	1.00	1.00
DP-8QAM	0.99	1.00	1.00
DP-16QAM	1.00	0.98	0.99

5.3.9. Evaluación reverse-transfer y discusión

Para estudiar si el formato utilizado en entrenamiento influye en la capacidad de generalización, se repitió el procedimiento entrenando detectores con operación normal de DP-8QAM y DP-16QAM y evaluando su desempeño al transferir hacia DP-QPSK. Los resultados muestran que, si bien los detectores entrenados con QAM pueden lograr buen desempeño in-format, su reverse-transfer hacia DP-QPSK presenta un deterioro más notorio. La figura 5.7 resume las matrices de confusión empleadas para este análisis (in-format y reverse-transfer).




Fig. 5.7: Resultados reverse-transfer: matrices de confusión para modelos entrenados en QAM evaluados in-format y al transferir a DP-QPSK. Fuente: Autoría propia.

Este comportamiento respalda la interpretación de que DP-QPSK exhibe una variabilidad más amplia en el comportamiento conjunto Pre-FEC BER-OSNR, lo que facilita aprender una representación de normalidad más transferible hacia formatos de mayor orden, mientras que el patrón normal en QAM no captura completamente la variabilidad observable al evaluar en DP-QPSK.

5.4. Clasificación y localización de soft-failures

Una vez que la etapa de detección levanta una alarma (condición anómala), el presente trabajo realiza una segunda etapa orientada a diagnóstico. En esta etapa no se busca volver a discriminar entre normal y falla, sino identificar el tipo de SF y asociarla a su ubicación más probable en el enlace. Para ello, la clasificación y localización se realizan utilizando telemetría de potencias reportadas por los EDFAs a lo largo de la cadena de amplificación. Dado que estas mediciones de potencia no dependen del formato de modulación de la misma forma que los indicadores de QoT, se combinan todos los formatos de modulación en un único conjunto de datos para aprendizaje supervisado.

En esta etapa, las muestras de operación normal no se utilizan como una clase objetivo, ya que el objetivo es discriminar entre tipos de fallas una vez detectada la anomalía. Sin embargo, las muestras normales sí se utilizan para calcular baselines de referencia necesarios para las características descritas a continuación. Adicionalmente, dado que la etapa de detección puede generar falsos positivos en operación, se incorpora un criterio explícito de rechazo para evitar forzar un diagnóstico de falla cuando no existe evidencia suficiente en las variables de telemetría.

5.4.1. Ingeniería de características a partir de mediciones del enlace

Sea P_k^{in} y P_k^{out} la potencia óptica de entrada y salida (en dBm) medida en el EDFA k , con $k \in \{1, 2, 3\}$. A partir de estas mediciones se derivan magnitudes físicas asociadas a amplificación y pérdidas entre etapas.

La ganancia de cada EDFA se calcula como:

$$G_k = P_k^{out} - P_k^{in}, \quad k \in \{1, 2, 3\}. \quad (5.9)$$

Las pérdidas efectivas entre etapas de amplificación (asociadas a los spans) se calculan como:

$$L_1 = P_1^{out} - P_2^{in}, \quad L_2 = P_2^{out} - P_3^{in}. \quad (5.10)$$

Para enfatizar desviaciones inducidas por SF, se definen características delta respecto a un baseline de operación normal. Sea $G_k^{(0)}$ y $L_s^{(0)}$ la ganancia media y pérdida media de span calculadas usando ventanas normales del subconjunto de entrenamiento. Con esto, los deltas se definen como:

$$\Delta G_k = G_k - G_k^{(0)}, \quad k \in \{1, 2, 3\}, \quad (5.11)$$

$$\Delta L_s = L_s - L_s^{(0)}, \quad s \in \{1, 2\}. \quad (5.12)$$

Finalmente, el vector de entrada para clasificación se define como:

$$\mathbf{f} = [\Delta G_1, \Delta G_2, \Delta G_3, \Delta L_1, \Delta L_2]. \quad (5.13)$$

5.4.2. Criterio de rechazo ante activaciones espurias de la detección

Como el clasificador se entrena para discriminar únicamente entre tipos de falla, una activación espuria de la etapa de detección (falso positivo) podría forzar al modelo a asignar una clase de SF aun cuando la telemetría sea consistente con operación normal. Para evitarlo, se incorpora un mecanismo simple de rechazo basado en la magnitud global de las desviaciones delta.

Se define un puntaje de desviación:

$$s_\Delta = \|\mathbf{f}\|_2, \quad (5.14)$$

y se fija un umbral τ_Δ utilizando únicamente ventanas normales del conjunto de entrenamiento (las mismas usadas para estimar los baselines), por ejemplo como un percentil alto:

$$\tau_\Delta = P_{99}(s_\Delta \mid \text{normal}). \quad (5.15)$$

En operación, si $s_\Delta \leq \tau_\Delta$, el diagnóstico se reporta como “no concluyente” (sin evidencia suficiente en telemetría para confirmar una SF) y no se ejecuta la localización. Si $s_\Delta > \tau_\Delta$, la muestra se considera compatible con un evento de SF y se aplica el clasificador multiclase sobre $\mathbf{f}$ para determinar tipo de falla y ubicación asociada.

5.4.3. Análisis exploratorio y selección de variables

Si bien es posible construir múltiples variables derivadas a partir de la telemetría disponible, en este trabajo se realizó un análisis exploratorio para seleccionar las variables más informativas para separar clases. En particular, se inspeccionaron histogramas condicionados por clase para observar cómo se distribuyen variables candidatas bajo cada tipo de falla.

Este análisis mostró que el conjunto $\mathbf{f}$ (Ecuación 5.13) entrega la separación más distintiva entre clases, ya que combina firmas complementarias: deltas de ganancia capturan degradaciones originadas en amplificación, mientras que deltas de span reflejan pérdidas entre etapas; el régimen NLI se expresa como un patrón conjunto a través de los deltas por efectos de redistribución de potencia en el enlace.




Fig. 5.8: Histogramas condicionados por clase para ΔG_1 , ΔG_2 , ΔG_3 , ΔL_1 y ΔL_2 . Fuente: Autoría propia.

5.4.4. Construcción del dataset y protocolo de entrenamiento

Para la clasificación supervisada, se descartan las muestras correspondientes a operación normal y se retienen únicamente las muestras de las cinco clases de falla. Los datos de todos los formatos de modulación se combinan en un único dataset, dado que las entradas están basadas en monitoreo de potencia y expresadas como desviaciones delta respecto a un baseline normal, lo cual las hace consistentes entre formatos.

El dataset se particiona en entrenamiento y prueba utilizando una división estratificada 80/20 para preservar la distribución de clases. Las muestras normales se utilizan únicamente para computar los baselines $G_k^{(0)}$ y $L_s^{(0)}$ desde el subconjunto de entrenamiento, y luego se excluyen de las etiquetas de clasificación supervisada.

Dado que las características están expresadas como deltas en dB, presentan magnitudes com-

parables, por lo que no se aplica normalización adicional en esta etapa.

5.4.5. Modelos evaluados para clasificación

Usando el vector $\mathbf{f}$ de la Ecuación 5.13, se evaluaron tres clasificadores supervisados para discriminar entre las cinco clases de falla:

- Random Forest, como ensamble de árboles de decisión capaz de capturar no linealidades e interacciones entre variables.
- SVM, como clasificador de máximo margen con capacidad de separación no lineal mediante kernel cuando corresponde.
- MLP, como red neuronal feed-forward capaz de aprender mapeos no lineales desde las características hacia las clases.

5.4.6. Resultados de clasificación

La Figura 5.9 resume las matrices de confusión en el subconjunto de prueba (80/20) para los tres modelos evaluados. En términos cualitativos, los resultados muestran clasificación casi perfecta para los tres enfoques, con Random Forest logrando separación perfecta entre clases.




Fig. 5.9: Matrices de confusión para clasificación multiclase en el subconjunto de prueba: (a) Random Forest, (b) SVM, (c) MLP. Fuente: Autoría propia.

Para un resumen escalar, la Tabla 5.9 reporta precisión, recall y F1-score como promedios ponderados por soporte de clase.

Tabla 5.9: Comparación de desempeño de clasificadores (promedios ponderados, 80/20).

Modelo	Precisión	Recall	F1-score
RF	1.0000	1.0000	1.0000
SVM	0.9989	0.9989	0.9989
MLP	0.9978	0.9978	0.9978

5.4.7. Mapeo de localización

La salida del clasificador habilita la localización al asociar cada categoría predicha con el segmento físico correspondiente del enlace. Este mapeo es consistente con la definición de características: los deltas de ganancia (ΔG_1 , ΔG_2 , ΔG_3) enfatizan degradaciones originadas en amplificación, mientras que los deltas de span (ΔL_1 , ΔL_2) capturan pérdidas excesivas entre etapas de amplificación. En el caso de NLI, la clase representa un régimen operacional.

Tabla 5.10: Regla de mapeo clase→ubicación en el enlace.

Clase predicha	Ubicación asociada
Ganancia reducida en E1	EDFA 1
Ganancia reducida en E2	EDFA 2
Atenuación adicional en S1	Primer Span
Atenuación adicional en S2	Segundo Span
Régimen NLI	Régimen no lineal (enlace)

Como resultado, el sistema en cascada entrega: (i) una alarma de detección basada en QoT; y (ii) condicionado a dicha alarma, un diagnóstico que identifica tipo de falla y su ubicación más probable. Si el criterio de rechazo de la Subsección 5.4.2 indica “no concluyente”, el sistema evita forzar una localización ante una activación espuria y retorna a monitoreo.

6. Conclusiones y trabajo futuro

6.1. Conclusiones

En el presente trabajo se abordó el problema operacional de gestionar degradaciones progresivas en enlaces ópticos mediante un enfoque en cascada que separa dos necesidades distintas en la operación real: por un lado, una detección temprana que actúa como señal de alerta; y por otro, un diagnóstico accionable que entrega el tipo de evento y su localización más probable. Esta separación permite que, en condición normal, el sistema opere de forma liviana usando únicamente indicadores de QoT en el receptor, y que solo ante una alarma se active un análisis más profundo basado en telemetría asociada a componentes del enlace, reduciendo complejidad y tiempos de diagnóstico.

La etapa de detección demostró que es posible discriminar entre operación normal y condición anómala utilizando variables de QoT disponibles en transceptores coherentes comerciales, sin requerir instrumentación adicional. El procesamiento por ventanas temporales permitió transformar series de tiempo en muestras compactas y estables, adecuadas para detección de anomalías bajo variabilidad operacional. El análisis de correlación confirmó redundancias estadísticas relevantes: tanto en Pre-FEC BER como en OSNR, la desviación estándar no aportaba información adicional significativa respecto a su promedio para el objetivo de detección. Esto justificó reducir el vector de entrada a dos variables (μ_{BER} y μ_{OSNR}), simplificando el detector, su calibración y su interpretabilidad, sin afectar el desempeño.

Entre los modelos evaluados para detección, el autoencoder alcanzó el desempeño más alto y se consolidó como el detector final. Un punto central fue definir un procedimiento de calibración consistente con operación real: el umbral de decisión se fijó usando exclusivamente datos normales (percentil 99 del error de reconstrucción), evitando utilizar fallas para ajustar el umbral y reduciendo el riesgo de sesgos hacia degradaciones específicas. En conjunto, la normalización por formato, el clipping y la calibración P99 permitieron estabilizar la decisión y habilitar transferencia entre formatos y escenarios no vistos durante entrenamiento.

Un resultado principal fue evidenciar detección robusta frente a cambios de formato de modulación y condiciones asociadas a carga dinámica. Al entrenar con DP-QPSK y evaluar en

DP-8QAM y DP-16QAM, el detector mantuvo desempeño alto, mostrando capacidad de generalización hacia formatos de mayor orden. En contraste, al entrenar en formatos QAM y transferir hacia DP-QPSK, se observó un deterioro más notorio. Esto respalda la interpretación de que DP-QPSK ofrece un patrón normal más informativo en el espacio conjunto BER–OSNR y, por lo tanto, constituye un mejor punto de partida para entrenar modelos con aspiración agnóstica al formato.

La etapa de diagnóstico (clasificación y localización) complementó la detección, transformando una alarma en una salida directamente útil para operación. Usando telemetría de potencias de entrada y salida de EDFAs y construyendo características derivadas coherentes con el comportamiento físico del enlace, fue posible discriminar clases de degradación y asociarlas a su origen dentro del enlace. La comparación de modelos supervisados mostró que Random Forest entrega desempeño sobresaliente en el escenario experimental considerado, lo que valida que la telemetría disponible puede utilizarse para un diagnóstico preciso y operacionalmente interpretable una vez que la detección se activa.

En síntesis, la contribución de este trabajo es un sistema completo y validado experimentalmente para monitoreo en cascada, que integra adquisición automatizada, procesamiento por ventanas, detección no supervisada calibrada con datos normales y diagnóstico supervisado basado en telemetría de componentes. El enfoque propuesto reduce la brecha entre resultados de laboratorio y requerimientos de operación, ya que entrega no solo detección de condiciones anómalas, sino también información accionable para orientar la respuesta del operador.

En relación con la hipótesis planteada, los resultados experimentales permiten validarla en términos operacionales. En particular, el desarrollo del enfoque en cascada, junto con el uso de características descriptivas obtenidas a partir de las variables disponibles en el enlace, permitió alcanzar desempeños generales superiores al 90 % tanto en la etapa de detección como en la etapa de diagnóstico. En detección, el modelo seleccionado mantuvo métricas altas al discriminar operación normal versus condición anómala y, además, conservó desempeño robusto al transferir entre formatos de modulación, lo que respalda el carácter agnóstico del enfoque frente al formato bajo el esquema de entrenamiento y recalibración propuesto. En diagnóstico, el uso de telemetría de potencias de entrada y salida de los EDFAs y de características derivadas coherentes con la física del enlace permitió clasificar y localizar las degradaciones con alta precisión, entregando una salida directamente accionable para operación.

Cabe destacar que, aunque la hipótesis considera media y desviación estándar como descriptores, el análisis realizado mostró que, para la detección, las desviaciones estándar de BER y OSNR

eran redundantes respecto a sus promedios, por lo que se optó por un vector mínimo sin pérdida de desempeño. Esta reducción no contradice la hipótesis; por el contrario, refuerza el resultado al mostrar que es posible cumplir el objetivo con un detector más simple, interpretable y fácil de calibrar. Finalmente, la evaluación bajo condiciones asociadas a carga dinámica —variando la presencia de canales adyacentes emulados— confirmó que el sistema mantiene su efectividad en escenarios representativos de operación. El único matiz relevante observado es que el formato utilizado para entrenar el detector influye en la transferencia inversa: entrenar con DP-QPSK ofrece una representación de normalidad más informativa y transferible hacia modulaciones de mayor orden, lo que fija una recomendación práctica para un futuro despliegue de este modelo propuesto.

6.2. Limitaciones

A pesar de los resultados, el alcance de validación se enmarca en restricciones experimentales que delimitan la generalización directa:

- La validación se realizó en una configuración específica de enlace (200 km, dos spans), por lo que su extrapolación a enlaces de mayor longitud o con más nodos requiere evaluación adicional.
- Se consideraron tres familias de degradación: ganancia reducida en amplificación, atenuación adicional por span y regímenes asociados a NLI bajo condiciones de carga dinámica. Existen otras degradaciones relevantes en redes operativas que no fueron abordadas en esta etapa.
- La operación de los EDFAs considerada en el enlace se configuró en un modo específico de control; el comportamiento del diagnóstico puede variar al utilizar modos alternativos como AGC, lo que exige estudios dedicados.

6.3. Trabajo futuro

Como extensión natural, el primer paso es ampliar el abanico de condiciones bajo las cuales se valida el sistema. Resulta relevante estudiar el comportamiento del diagnóstico cuando los EDFAs operan en modo AGC, ya que este modo altera la relación entre potencias y ganancias observables, pudiendo modificar la separabilidad de clases y la estabilidad de las características tipo delta. Junto con ello, es importante ampliar el catálogo de degradaciones: fallas asociadas

a filtrado (por ejemplo desplazamientos o estrechamientos), derivas de frecuencia del láser, incrementos de ruido por degradación de amplificación, degradaciones intermitentes y otros eventos que en operación suelen manifestarse como deterioro gradual de QoT.

También es necesario avanzar hacia portabilidad del enfoque a configuraciones de enlace distintas. Esto incluye validar el pipeline en enlaces con mayor número de spans/amplificadores, y estudiar estrategias de localización cuando existan más segmentos candidatos. En esa línea, es deseable definir mecanismos que mantengan interpretabilidad física (por ejemplo, localización jerárquica por tramo/dispositivo) y que permitan reutilizar el criterio de diagnóstico sin rediseñar el sistema desde cero para cada topología.

Desde el punto de vista de despliegue, un aspecto clave es la adaptación frente a deriva lenta en el comportamiento normal. En redes reales, la distribución de BER, OSNR y potencias cambia con el tiempo por envejecimiento, reconexiones o reconfiguraciones. Por ello, se debe estudiar recalibración online del umbral, actualización segura de parámetros de normalización y detección sin introducir inestabilidad ni aumentar falsos positivos. En paralelo, resulta valioso incorporar medidas de confianza o incertidumbre tanto en detección como en diagnóstico, de modo que el sistema pueda priorizar alarmas, identificar casos ambiguos y, si corresponde, gatillar mediciones adicionales o estrategias de verificación.

Finalmente, una extensión de alto impacto es integrar este pipeline con herramientas de monitoreo y control de red, evaluando latencias reales de decisión, costo de muestreo, y el beneficio operacional en tiempos de diagnóstico y acciones correctivas. Esto permitiría cerrar el ciclo desde una alarma temprana hasta una respuesta más rápida y dirigida, acercando el sistema a un entorno de operación continuo.

7. ANEXOS

7.1. ANEXO: Figuras Complementarias

Este apéndice incluye figuras adicionales que muestran diferentes configuraciones de enlaces ópticos utilizadas en las investigaciones previas mostradas en el Capítulo 1 sobre el estado del arte.




Fig. 7.1: .

Set-up utilizado en la investigación [4].




Fig. 7.2: Set-up utilizado en la investigación [27].




Fig. 7.3: Set-up utilizado en la investigación [14].




Fig. 7.4: Set-up utilizado en la investigación [24].

7.2. ANEXO: Código Utilizado

El siguiente listado muestra un extracto representativo del script principal desarrollado en *Python* para la automatización de la recolección de datos y la configuración dinámica del enlace óptico. Este extracto ilustra las configuraciones iniciales, las definiciones de las funciones de comunicación con los equipos (transceptor Cassini vía SSH; EDFAs y VOAs vía API), y la lógica del bucle de muestreo por ventanas de tiempo.

```

1  import paramiko
2  import time
3  import re
4  import requests
5  import csv
6  import random
7  from datetime import datetime
8  import json
9
10 # --- Configuración SSH Receptor ptico ---
11 hostname_receptor = '10.100.2.103'
12 port_receptor = 22
13 username_receptor = 'ocnos'
14 password_receptor = 'ocnos'
15
16 # --- Configuración API EDFA/VOA ---
17 url_base_api = 'http://localhost:9090/'
18 headers_api = {
19     'Accept': 'application/json',
20     'Content-Type': 'application/x-www-form-urlencoded; charset=UTF-8',
21     'Cookie': 'JSESSIONID=...', # !Advertencia! Esta JSESSIONID puede expirar
22     'Referer': 'http://localhost:9090/goGlobal.action',
23     'X-Requested-With': 'XMLHttpRequest'
24 }
25
26 # --- Configuración de Muestreo ---
27 ventana_tiempo = 60 # segundos por ventana (1 minuto)
28 intervalo_lectura = 1.0 # segundos entre lecturas
29
30 # --- Definición de Fases de Ejecución (Simplificado) ---
31 # Cada tupla es: (nombre_fase, num_ventanas, id_falla, ...)
32 fases_muestreo_anexo = [
33     ("Operación_Normal", 500, 0, ...), # 500 ventanas para estado normal

```

```

34     ("Falla_EDFA1", 250, 1, ...),      # 250 ventanas para falla EDFA1
35     # ... otras fases de falla, según la distribución detallada en el Capí
        tulo 3 ...
36     ("Falla_NLI_(1_canal)", 100, 5, ...)
37 ]
38
39 # --- Funciones de Control de Dispositivos ---
40 def generar_valor_aleatorio(rango):
41     min_val, max_val, resolucion = rango
42     num_pasos = int(round((max_val - min_val) / resolucion, 2)) + 1
43     return round(min_val + random.randint(0, num_pasos - 1) * resolucion, 2)
44
45 def configurar_edfa(slot, ganancia):
46     url = url_base_api + 'setPumpInfo.action'
47     edfa_data = { "realName": f"192.168.126.1_Shelf1_{slot}_SubSlot0", "
        oaPumpModeValue": str(ganancia), "oaPumpControlMode": "2", ... }
48     payload_final = {'data': json.dumps(edfa_data)}
49     try: requests.post(url, headers=headers_api, data=payload_final).
        raise_for_status()
50     except requests.exceptions.RequestException as e: print(f"ERROR: EDFA_{
        slot}_config_{e}")
51
52 def configurar_voa(slot, atenuacion):
53     url = url_base_api + 'setVoaPluggableData.action'
54     voa_data = { "realName": f"192.168.126.1_Shelf1_{slot}
        _SubSlot0_Port3_SubPort0", "voaPluggableAttenuation": str(atenuacion),
        ... }
55     payload_final = {'data': json.dumps(voa_data)}
56     try: requests.post(url, headers=headers_api, data=payload_final).
        raise_for_status()
57     except requests.exceptions.RequestException as e: print(f"ERROR: VOA_{
        slot}_config_{e}")
58
59 # --- Funciones de Extracción de Datos ---
60 def extraer_datos_receptor_optico(shell):
61     shell.send('show_coherent-module_3\n'); time.sleep(0.1); output = ""; #
        ... (bucle para leer salida completa) ...
62     ber_match = re.search(r'Current_PRE_FEC_BER\s+:\s+([0-9\.e-]+)', output)
63     input_power_match = re.search(r'Current_Input_Power\s+:\s+([0-9\.\-]+)',
        output)
64     osnr_match = re.search(r'Current_OSNR_Estimate\s+:\s+([0-9\.\-]+)', output)
65     return {'BER': ber_match.group(1), 'OSNR': osnr_match.group(1), '

```

```

        'PotenciaReceptor': float(input_power_match.group(1)) if
        input_power_match else None}

66
67 def obtener_potencias_edfa():
68     potencias = {}; edfa_slots = { 'Slot1': 'EDFA1', 'Slot3': 'EDFA2', 'Slot4
        ': 'EDFA3' };
69     for slot, edfa_name in edfa_slots.items():
70         data = {'realName': f'192.168.126.1_Shelf1_{slot}_SubSlot0'};
71         try: result = requests.post(url_base_api + 'getEdfaConfigInfo.action',
            , headers=headers_api, data=data).json();
72             potencias[f'PotenciaEntrada{edfa_name}'] = result.get('
                oaPortOpticalPower1') / 100 if result.get('oaPortOpticalPower1
                ') is not None else None;
73             potencias[f'PotenciaSalida{edfa_name}'] = result.get('
                oaPortOpticalPower2') / 100 if result.get('oaPortOpticalPower2
                ') is not None else None;
74         except requests.exceptions.RequestException as e: potencias[f'
            PotenciaEntrada{edfa_name}'] = None; potencias[f'PotenciaSalida{
            edfa_name}'] = None;
75     return potencias
76
77 # --- Función Principal (Bucle de Adquisición) ---
78 def main_acquisition_loop_simplified():
79     # ... (establecer ssh_receptor, shell_receptor, abrir csvfile, writer)
    ...
80     for nombre_fase, num_ventanas_fase, id_falla_actual, _, _, _, _ in
        fases_muestreo_anexo:
81         for ventana in range(num_ventanas_fase):
82             # ... (Configurar aleatoriamente los dispositivos) ...
83             for segundo in range(ventana_tiempo):
84                 datos_receptor = extraer_datos_receptor_optico(None) # None
                    for simplified_shell in extract
85                 datos_edfa = obtener_potencias_edfa()
86                 if datos_receptor and datos_edfa:
87                     row = { 'timestamp_lectura': datetime.now().isoformat(
                        timespec='milliseconds'), 'segundo_en_ventana':
                        segundo, 'BER': datos_receptor.get('BER'), 'OSNR':
                        datos_receptor.get('OSNR'), 'PotenciaReceptor':
                        datos_receptor.get('PotenciaReceptor'), 'id_falla':
                        id_falla_actual, **datos_edfa } # Simplified dict
                        merging
88                     # writer.writerow(row) # Descomentar para escribir

```



```
89         time.sleep(intervalo_lectura)
90     # ... (manejo de excepciones y cierre de conexiones) ...
```

Listing 7.1: Código

7.3. ANEXO: Hojas de Datos y Documentación Técnica Relevante

Este apéndice proporciona extractos o referencias a las hojas de datos (datasheets) y documentación técnica de los componentes utilizados en el *set-up* experimental.

Item #	EDFA100S	EDFA100P
Amplifier Specifications (at 1000 mA Pump Current)		
Operating Wavelength Range ^a	1530 nm - 1565 nm	
Saturated Output Power (@ 3 dBm Input Power) ^{b,c}	>20 dBm	
Small Signal Gain (@ -20 dBm Input Power) ^b	>30 dB	>28 dB
Noise Figure (@ 3 dBm Input Power) ^b	<5 dB	
Output Power Stability (@ 3 dBm Input Power)	<±2% Over 24 Hours (After 15 Minute Warm-Up, for Ambient Temperature ±2 °C)	
Total Dispersion within Amplifier	<0.06 ps/nm	
Laser Class	3B	
Fiber Specifications		
Output Polarization	Random	Linear, Aligned to Slow Axis
Polarization Extinction Ratio	N/A	>25 dB
Polarization-Dependent Gain	<0.5 dB	N/A
Return Loss at Input Port	>50 dB	
Input / Output Isolation	>30 dB	
Input / Output Fiber Type	SMF-28-J9	PM1550-XP
Input / Output Fiber Connectors	FC/APC Compatible, 2.0 mm Narrow Key	

- The wavelength range over which the output power (at 3 dBm input power) does not fall below 18 dBm.
- Specified at 1550 nm. Please refer to published data on Thorlabs website¹ for typical curves showing the variation of each parameter.
- Please refer to published data on Thorlabs website¹ on the scaling of the output power vs. the input power.

Absolute Maximum Ratings	
Absolute Maximum Input Power	10 dBm
Absolute Maximum Output Power	23 dBm
Operating Temperature	15 to 35 °C
Storage Temperature	0 to 50 °C

Fig. 7.5: Especificaciones del EDFA Thorlabs 100S. Fuente:[37]

	Condition	100G DP-QPSK Edge Aggregation	100G DP-QPSK Long Haul Transport	200G DP-8QAM Long Haul Transport	200G DP-16QAM Metro Transport
Baud rate	BER at 10^{-15} post FEC	~28 Gbaud	~31 Gbaud	~43 Gbaud	~31 Gbaud
Typical OSNR		14 dB	12 dB	18 dB	20 dB
Minimum Rx sensitivity	>35dB OSNR	-29 dBm	-30 dBm	-24 dBm	-22 dBm
FEC	7% overhead	SC-FEC (9.4 dB/4.5E ⁻³)	-	-	-
(Net Coding Gain/Threshold)	15% overhead	-	SD-FEC (10.3 dB/1.45E ⁻²)	SD-FEC (10.3 dB/1.45E ⁻²)	SD-FEC (10.3 dB/1.45E ⁻²)

Fig. 7.6: Extracto del datasheet del trasceptor coherente Lumentum CFP2-DCO. Fuente:[38]

Fibre attributes			
Attribute	Detail	Value	Unit
Mode field diameter	Wavelength	1310	nm
	Range of nominal values	8.6-9.2	μm
	Tolerance	± 0.4	μm
Cladding diameter	Nominal	125.0	μm
	Tolerance	± 0.7	μm
Core concentricity error	Maximum	0.6	μm
Cladding noncircularity	Maximum	1.0	%
Cable cut-off wavelength	Maximum	1260	nm
Macrobending loss	Radius	30	mm
	Number of turns	100	
	Maximum at 1625 nm	0.1	dB
Proof stress	Minimum	0.69	GPa
Chromatic dispersion parameter 3-term Sellmeier fitting (1260 nm to 1460 nm)	$\lambda_{d\text{min}}$	1 300	nm
	$\lambda_{d\text{max}}$	1 324	nm
	$S_{0\text{min}}$	0.073	ps/(nm ² × km)
	$S_{0\text{max}}$	0.092	ps/(nm ² × km)
Linear fitting (1460 nm to 1625 nm)	Minimum at 1550 nm	13.3	ps/(nm × km)
	Maximum at 1550 nm	18.6	ps/(nm × km)
	Minimum at 1625 nm	17.2	ps/(nm × km)
	Maximum at 1625 nm	23.7	ps/(nm × km)
Cable attributes			
Attribute	Detail	Value	Unit
Attenuation coefficient (Note 1)	Maximum from 1310 nm to 1625 nm (Note 2)	0.40	dB/km
	Maximum at 1383 nm ± 3 nm after hydrogen ageing (Note 3)	0.40	dB/km
	Maximum at 1530-1565 nm	0.30	dB/km
PMD coefficient (Note 4, 5)	M	20	cables
	Q	0.01	%
	Maximum PMD _Q	0.20	ps/ $\sqrt{\text{km}}$

Fig. 7.7: Atributos de la fibra óptica monomodo estándar G.652.D según la recomendación ITU-T. Fuente: [39]

Especificaciones

Cantidad de ranuras	7 ranuras	Tipo de distribuidor	Montaje en rack
Fuente de alimentación	Doble alimentación AC, 100V~240VAC Intercambiable en caliente	Consumo de energía	< 300W
Humedad relativa	10% ~ 90% (sin condensación)	Tipo de gestión	WEB, SNMP v2
Interfaz de red	2x SFP LAN puertos 100Base-X 4x RJ45 LAN puertos 10/100Base-T	Dimensiones (HxWxD)	3.46"x17.48"x12.80" (88×444×325mm)
Temperatura de funcionamiento	-10 a 50°C (14 a 122°F)	Temperatura de almacenamiento	-10 a 70°C (14 a 158°F)

Fig. 7.8: Extracto del datasheet del Chasis M6200-CH2U. Fuente:[40]

Tipo de amplificador	Amplificador de refuerzo	Longitud de onda de funcionamiento	1529nm-1561nm
Ganancia óptica	11-21dB	Ganancia plana	1.5dB (Típica)
Potencia de entrada	-25dBm~+7dBm	Potencia de salida saturada	≤20dBm
Figura de ruido	<5.5dB	Conector óptico	LC/UPC
Pérdida dependiente de la polarización	<0.5dB	Consumo de energía	≤15W
Modo de funcionamiento	AGC/APC	Tipo de gestión	SNMP, WEB
Temperatura de funcionamiento	-10 a 50°C (14 a 122°F)	Temperatura de almacenamiento	-20 a 80°C (-4 a 176°F)
Peso	0.39kg	Carcasa	Módulo enchufable (Ocupa 1 ranura en chasis gestionado M6200)

Fig. 7.9: Extracto del datasheet del EDFA Booster Amplifier. Fuente:[41]

Tipo de amplificador	Preamplificador	Longitud de onda de funcionamiento	1529nm-1561nm
Ganancia óptica	20-30dB	Ganancia plana	1.5dB (típica)
Potencia de entrada	-32dBm~+4dBm	Potencia de salida saturada	≤16dBm
Figura de ruido	<5.5dB	Conector óptico	LC/UPC
Modo de funcionamiento	AGC/APC	Tipo de gestión	SNMP v2, WEB
Pérdida dependiente de la polarización	<0.5dB	Consumo de energía	≤15W
Temperatura de funcionamiento	-10 a 50°C (14 a 122°F)	Temperatura de almacenamiento	-20 a 80°C (-4 a 176°F)
Peso	0.405kg	Carcasa	Módulo enchufable (ocupa 1 ranura en chasis gestionado M6200)

Fig. 7.10: Extracto del datasheet del EDFA Pre-Amplifier. Fuente:[42]

Bibliografía

- [1] A. P. Vela, M. Ruiz, F. Fresi, N. Sambo, F. Cugini, G. Meloni, L. Potì, L. Velasco, and P. Castoldi, “Ber degradation detection and failure identification in elastic optical networks,” *Journal of Lightwave Technology*, vol. 35, no. 21, pp. 4595–4604, 2017.
- [2] D. A. A. Mello, K. S. Mayer, A. F. Escallón-Portilla, D. S. Arantes, R. P. Pinto, and C. E. Rothenberg, “When digital twins meet optical networks operations,” in *2023 Optical Fiber Communications Conference and Exhibition (OFC)*, 2023, pp. 1–3.
- [3] R. Wang, J. Zhang, Z. Gu, M. Ibrahimi, B. Zhang, F. Musumeci, M. Tornatore, and Y. Ji, “Digital-twin-assisted meta learning for soft-failure localization in roadm-based optical networks,” *Journal of Optical Communications and Networking*, vol. 16, no. 7, pp. C11–C19, 2024.
- [4] S. Shahkarami, F. Musumeci, F. Cugini, and M. Tornatore, “Machine-learning-based soft-failure detection and identification in optical networks,” in *2018 Optical Fiber Communications Conference and Exposition (OFC)*, 2018, pp. 1–3.
- [5] D. Sequeira, M. Ruiz, N. Costa, A. Napoli, J. Pedro, and L. Velasco, “Ocata: a deep-learning-based digital twin for the optical time domain,” *Journal of Optical Communications and Networking*, vol. 15, no. 2, pp. 87–97, 2023.
- [6] L. Shu, Z. Yu, Z. Wan, J. Zhang, S. Hu, and K. Xu, “Dual-stage soft failure detection and identification for low-margin elastic optical network by exploiting digital spectrum information,” *Journal of Lightwave Technology*, vol. 38, no. 9, pp. 2669–2679, 2020.
- [7] A. P. Vela, B. Shariati, M. Ruiz, J. Comellas, and L. Velasco, “Soft failure localization in elastic optical networks,” in *2018 20th International Conference on Transparent Optical Networks (ICTON)*, 2018, pp. 1–4.
- [8] X. Chen, C.-Y. Liu, R. Proietti, Z. Li, and S. J. B. Yoo, “Automating optical network fault management with machine learning,” *IEEE Communications Magazine*, vol. 60, no. 12, pp. 88–94, 2022.
- [9] F. Musumeci, C. Rottondi, A. Nag, I. Macaluso, D. Zibar, M. Ruffini, and M. Tornatore,

- “An overview on application of machine learning techniques in optical networks,” *IEEE Communications Surveys & Tutorials*, vol. 21, no. 2, pp. 1383–1408, 2019.
- [10] L. Z. Khan, J. Pedro, N. Costa, L. De Marinis, A. Napoli, and N. Sambo, “Data augmentation to improve performance of neural networks for failure management in optical networks,” *Journal of Optical Communications and Networking*, vol. 15, no. 1, pp. 57–67, 2023.
 - [11] S. Barzegar, M. Ruiz, and L. Velasco, “Soft-failure localization and time-dependent degradation detection for network diagnosis,” in *2020 22nd International Conference on Transparent Optical Networks (ICTON)*, 2020, pp. 1–4.
 - [12] K. Mitropoulou, I. Sartzetakis, and E. Varvarigos, “Soft failure detection, categorization and localization,” in *2020 22nd International Conference on Transparent Optical Networks (ICTON)*, 2020, pp. 1–4.
 - [13] B. Shariati, M. Ruiz, J. Comellas, and L. Velasco, “Feature-based optical spectrum monitoring for failure detection and identification,” in *2019 21st International Conference on Transparent Optical Networks (ICTON)*, 2019, pp. 1–4.
 - [14] A. N. Ribeiro, R. F. Sales, F. R. Lobato, J. Costa, M. F. Silva, A. Sgambelluri, L. Valcarenghi, and L. Wosinska, “Pca-assisted fuzzy clustering approach for soft-failure detection in optical networks,” in *2024 International Conference on Optical Network Design and Modeling (ONDM)*, 2024, pp. 1–5.
 - [15] H. A. O. Espinoza, “Detección e identificación de “soft failures” en enlaces Ópticos en base a machine learning,” Memoria de Título, Universidad de Concepción, Facultad de Ingeniería, Concepción, Chile, agosto 2024, memoria para optar al título de Ingeniero Civil en Telecomunicaciones. Profesor Guía: Gabriel Alejandro Saavedra Mondaca.
 - [16] K. Sun, Z. Yu, L. Shu, Z. Wan, H. Huang, Y. Lei, and K. Xu, “Digital residual spectrum-based generalized soft failure detection and identification in optical networks,” *IEEE Transactions on Communications*, vol. 71, no. 1, pp. 324–338, 2023.
 - [17] A. Yeganehfallah, A. Sgambelluri, A. Pacini, L. Valcarenghi, and M. F. Silva, “Effectiveness of confidentiality-preserving clustering algorithms for soft failure detection in optical networks,” in *2024 IEEE 25th International Conference on High Performance Switching and Routing (HPSR)*, 2024, pp. 87–92.

- [18] M. F. Silva, A. Pacini, A. Sgambelluri, F. Paolucci, and L. Valcarenghi, “Confidentiality-preserving machine learning scheme to detect soft-failures in optical communication networks,” in *2022 European Conference on Optical Communication (ECOC)*, 2022, pp. 1–4.
- [19] M. F. Silva, A. Sgambelluri, A. Pacini, F. Paolucci, A. Green, D. Mascarenas, and L. Valcarenghi, “Confidentiality-preserving machine learning algorithms for soft-failure detection in optical communication networks,” *Journal of Optical Communications and Networking*, vol. 15, no. 8, pp. C212–C222, 2023.
- [20] X. Chen, C.-Y. Liu, R. Proietti, J. Yin, Z. Li, and S. J. B. Yoo, “On cooperative fault management in multi-domain optical networks using hybrid learning,” *IEEE Journal of Selected Topics in Quantum Electronics*, vol. 28, no. 4: Mach. Learn. in Photon. Commun. and Meas. Syst., pp. 1–9, 2022.
- [21] S. Ghosh and A. Adhya, “Soft failure detection and identification in optical networks using cascaded deep learning model,” *Computer Networks*, vol. 262, p. 111159, 2025.
- [22] H. Lun, M. Fu, X. Liu, Y. Wu, L. Yi, W. Hu, and Q. Zhuge, “Soft failure identification for long-haul optical communication systems based on one-dimensional convolutional neural network,” *Journal of Lightwave Technology*, vol. 38, no. 11, pp. 2992–2999, 2020.
- [23] H. Lun, M. Fu, Y. Zhang, H. Jiang, L. Yi, W. Hu, and Q. Zhuge, “A gan based soft failure detection and identification framework for long-haul coherent optical communication systems,” *Journal of Lightwave Technology*, vol. 41, no. 8, pp. 2312–2322, 2023.
- [24] L. Z. Khan, J. Pedro, O. Ayoub, N. Costa, A. Sgambelluri, L. De Marinis, A. Napoli, and N. Sambo, “Optimizing deep learning-based failure management in optical networks by monitoring relative neural activity,” in *2024 International Conference on Optical Network Design and Modeling (ONDM)*, 2024, pp. 1–3.
- [25] D. J. Elson, G. Saavedra, K. Shi, D. Semrau, L. Galdino, R. Killey, B. C. Thomsen, and P. Bayvel, “Investigation of bandwidth loading in optical fibre transmission using amplified spontaneous emission noise,” *Opt. Express*, vol. 25, no. 16, pp. 19 529–19 537, Aug 2017.
- [26] M. F. Silva, A. Pacini, A. Sgambelluri, and L. Valcarenghi, “Learning long- and short-term temporal patterns for ml-driven fault management in optical communication networks,” *IEEE Transactions on Network and Service Management*, vol. 19, no. 3, pp. 2195–2206, 2022.

- [27] K. Sun, Z. Yu, L. Shu, Z. Wan, H. Huang, and K. Xu, "Experimental demonstration of soft failure identification based on digital residual spectrum and machine learning," in *2021 International Conference on UK-China Emerging Technologies (UCET)*, 2021, pp. 81–84.
- [28] S. Jia. (2019, apr) Forward error correction (fec): A primer on the essential element for optical transmission interoperability. [Online]. Available: <https://www.cablelabs.com/blog/whats-next-coherent-pon>
- [29] S. R. Manríquez Beyer, "Laboratorio de sistemas y redes ópticas flexibles basado en wss," Master's thesis, Pontificia Universidad Católica de Valparaíso, Escuela de Ingeniería Eléctrica, Valparaíso, Chile, jul 2017.
- [30] International Telecommunication Union, "Series G: Transmission Systems and Media, Digital Systems and Networks - Characteristics of a single-mode optical fibre and cable," ITU-T, Recommendation G.652, November 2016.
- [31] Y. Regaya, F. Fadli, and A. Amira, "Point-denoise: Unsupervised outlier detection for 3d point clouds enhancement," *Multimedia Tools and Applications*, vol. 80, pp. 1–17, 07 2021.
- [32] I. Khater, I. Nabi, and G. Hamarneh, "A review of super-resolution single-molecule localization microscopy cluster analysis and quantification methods," *Patterns*, vol. 1, p. 100038, 06 2020.
- [33] H. Ahmed, M. L. D. Wong, and A. Nandi, "Intelligent condition monitoring method for bearing faults from highly compressed measurements using sparse over-complete features," *Mechanical Systems and Signal Processing*, vol. 99, pp. 459–477, 01 2018.
- [34] M. S. Chowdhury, "Comparison of accuracy and reliability of random forest, support vector machine, artificial neural network and maximum likelihood method in land use/cover classification of urban setting," *Environmental Challenges*, vol. 14, p. 100800, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2667010023001233>
- [35] A. Massaoudi, F. Echouchene, B. A. Mossaad, A. Berguiga, A. Harchay, and H. Belmabrouk, "Modeling of the biosorption of fe(iii) ions by olive-stone activated carbon," *Applied Organometallic Chemistry*, vol. 38, 02 2024.
- [36] T. Mano, A. D'Amico, E. Virgillito, G. Borraccini, Y.-K. Huang, K. Anazawa, H. Nishizawa, T. Wang, K. Asahi, and V. Curri, "Modeling transceiver ber-osnr characteristic for qot estimation in short-reach systems," in *2023 International Conference on Optical Network*

Design and Modeling (ONDM), 2023, pp. 1–3.

- [37] Thorlabs, *EDFA100S and EDFA100P: Erbium Doped Fiber Amplifiers — Operating Manual*, 2023, tTN118382-D02, Rev C, June 27, 2023. [Online]. Available: <https://l-optics.ru/upload/iblock/588/gm7z87nge6sxn9tcfocevmiyqs17dd8p/EDFA100S-Manual.pdf>
- [38] Lumentum Operations LLC. (2020) The benefits of multi-rate coherent transponders in cfp2 form factor. White paper. Document code: Cfp2-dco-wp-oc-ae 30179643 001 0320. [Online]. Available: <https://resource.lumentum.com/s3fs-public/technical-library-items/cfp2-dco-wp-oc-ae.pdf>
- [39] International Telecommunication Union, “Characteristics of a single-mode optical fibre and cable,” ITU-T, Recommendation G.652, Aug. 2024, approved 2024-08-29. [Online]. Available: <https://handle.itu.int/11.1002/1000/16060>
- [40] FS.com. M6200 series 2u managed chassis for 10g wdm network. [Online]. Available: <https://www.fs.com/uk/products/107371.html>
- [41] FS.com. 20 dBm output booster DWDM EDFA pluggable module, 16 dB gain. [Online]. Available: https://www.fs.com/products/107366.html?now_cid=837
- [42] FS.com. 25 dB gain optical pre-amplifier EDFA pluggable module, 16 dBm output. [Online]. Available: <https://www.fs.com/eu-en/products/107367.html>